

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# **ZAVRŠNI RAD**

**Matej Stanić**

Zagreb, 2019. godine

SVEUČILIŠTE U ZAGREBU  
FAKULTET STROJARSTVA I BRODOGRADNJE

# ZAVRŠNI RAD

Voditelj rada:

Doc. dr. sc. Zvonimir Tomičević

Student:

Matej Stanić

Zagreb, 2019. godine

Izjavljujem da sam ovaj rad izradio samostalno koristeći stečena znanja tijekom studija i navedenu literaturu.

Prije svega, zahvaljujem se svom mentoru doc.dr.sc. Zvonimiru Tomičeviću na vrhunskom mentorstvu, pruženim savjetima, neumornom vodstvu i motiviranju, predanosti, strpljivosti te na vremenu uloženom kako bi mi pomogao izraditi ovaj završni rad.

Iskreno se zahvaljujem svojim roditeljima što su mi omogućili studiranje, sestri, braći, djevojci i prijateljima što su mi uljepšali preddiplomski studij.

Na kraju, zahvalio bih se dragom Bogu za sva darovana znanja i vještine te za sve ljude s kojima svakodnevno surađujem.



SVEUČILIŠTE U ZAGREBU  
**FAKULTET STROJARSTVA I BRODOGRADNJE**



Središnje povjerenstvo za završne i diplomske ispite  
Povjerenstvo za završne ispite studija strojarstva za smjerove:  
procesno-energetski, konstrukcijski, brodstrojarski i inženjersko modeliranje i računalne simulacije

Sveučilište u Zagrebu Fakultet strojarstva i brodogradnje	
Datum	Prilog
Klasa:	
Ur.broj:	

## ZAVRŠNI ZADATAK

Student: **Matej STANIĆ**

Mat. br.: 0035204179

Naslov rada na  
hrvatskom jeziku:

**Određivanje rezolucije pomaka i deformacija lokalnom i globalnom metodom korelacije digitalnih slika na različitim umjetnim teksturama**

Naslov rada na  
engleskom jeziku:

**Determination of displacement and strain resolution using local and global digital image correlation methods on different artificial textures**

Opis zadatka:

Uslijed opterećenja realnih inženjerskih konstrukcija ili ispitnih uzoraka u kontroliranim laboratorijskim uvjetima materijal doživljava promjene koje nazivamo ponašanje materijala. Cilj eksperimentalne mehanike je odrediti odziv materijala uslijed narinutog mehaničkog opterećenja. S razvojem digitalnih kamera javljaju se i nove beskontaktna metode mjerenja cijelog polja pomaka i/ili deformacija. U eksperimentalnoj mehanici najčešće se koristi metoda korelacije digitalne slike (eng. *DIC – Digital Image Correlation*) koja se zasniva na praćenju promjena na površini opterećenog objekta. Prilikom ispitivanja neophodno je da na promatranom objektu postoji kontrast koji se manifestira na digitalnoj slici kao različita vrijednost sive skale boje određenog piksela. Iz tog razloga se na površinu ispitnog uzorka nanosi umjetna tekstura/raster.

U ovom radu je potrebno odrediti standardnu rezoluciju pomaka i deformacija za lokalni i globalni korelacijski algoritam. Mjerenja je potrebno provesti na dvije različite umjetne teksture koje će biti pripremljene klasičnom sprej metodom i airbrush metodom. Osim toga, potrebno je ispitati utjecaj veličine faseta tj. mreže konačnih elemenata na mjernu nesigurnost primijenjenih korelacijskih tehnika. Tijekom rada potrebno je:

1. Upoznati se s radom optičkog mjernog sustava Aramis i RT3 Correli korelacijskim algoritmom.
2. Odrediti standardnu rezoluciju pomaka i deformacija na umjetnim teksturama izrađenim klasičnom sprej metodom te airbrush-om.
3. Analizirati rezultate mjerne nesigurnosti lokalnog i globalnog DIC algoritma uzimajući u obzir veličinu elemenata.
4. Usporediti dobivene rezultate standardnih rezolucija pomaka i deformacija za primjenjene metode korelacije digitalne slike.

U radu navesti korištenu literaturu i eventualno dobivenu pomoć.

Zadatak zadan:

Rok predaje rada:

Predviđeni datumi obrane:

29. studenog 2018.

1. rok: 22. veljače 2019.

1. rok: 25.2. - 1.3. 2019.

2. rok (izvanredni): 28. lipnja 2019.

2. rok (izvanredni): 2.7. 2019.

3. rok: 20. rujna 2019.

3. rok: 23.9. - 27.9. 2019.

Zadatak zadao:

Predsjednik Povjerenstva:

Doc. dr. sc. Zvonimir Tomičević

Prof. dr. sc. Igor Balen

## SADRŽAJ

SADRŽAJ .....	I
POPIS SLIKA .....	II
POPIS TABLICA.....	IV
POPIS ENGLJSKIH SKRAĆENICA .....	V
SAŽETAK.....	V
SUMMARY .....	VI
1. UVOD .....	1
2. METODA KORELACIJE DIGITALNE SLIKE .....	3
2.1. Primjena metode korelacije digitalne slike.....	3
2.2. Tekstura .....	6
2.3. Lokalni pristup metodi korelacije digitalne slike .....	10
2.4. Globalni pristup metodi korelacije digitalne slike.....	15
2.5. Uzroci pogrešaka u metodi korelacije digitalne slike.....	20
3. EKSPERIMENTALNA MJERENJA .....	23
3.1. Priprema uzoraka .....	23
3.2. Provedba mjerenja .....	24
4. REZULTATI LOKALNOG I GLOBALNOG DIC PRISTUPA .....	28
4.1. Izmjerena polja pomaka.....	29
4.2. Izmjerena polja deformacija .....	33
5. ODREĐIVANJE STANDARDNE REZOLUCIJE POMAKA I DEFORMACIJA .....	37
5.1. Usporedba lokalnog i globalnog pristupa .....	37
5.2. Usporedba sprej i <i>airbrush</i> teksture.....	42
ZAKLJUČAK .....	44
LITERATURA.....	46

## POPIS SLIKA

Slika 1. Shematski prikaz 2D DIC optičkog postava [2].	3
Slika 2. Shematski prikaz stereo mjerenja s dvije kamere [1].	5
Slika 3. Osnovni dijelovi CT-uređaja [6].	5
Slika 4. Umjetna tekstura.	6
Slika 5. Valjci za nanošenje teksture [8].	7
Slika 6. Numerički dobivena tekstura [9].	8
Slika 7. Papir za WTP prijenos teksture [11].	9
Slika 8. Postupak mikrolitografije: nanošenje sloja PMMA (a), izlaganje snopu elektrona (b), nanošenje sloja zlata (d), konačna tekstura nakon uklanjanja PMMA (e) [12].	9
Slika 9. Pravokutne fasete u referentnoj konfiguraciji (a) i deformiranoj konfiguraciji (b) ....	10
Slika 10. Određivanje pomaka i deformiranja fasete [2].	10
Slika 11. Distribucija CC korelacijskog kriterija [2].	13
Slika 12. Prikaz područja interesa u referentnoj i deformiranoj konfiguraciji [15].	15
Slika 13. Polje reziduala korišteno za praćenje rasta mikropukotina.	17
Slika 14. Prikaz grupiranja piksela veličine 1x1 mm kojim se dobije super-piksel veličine 2x2 mm [17].	18
Slika 15. Odstupanje od pravog kuta između uzorka i optičke osi uređaja [18].	21
Slika 16. Utjecaj distorzije slike na vrijednosti pomaka [19].	21
Slika 17. Umjetna tekstura dobivena: sprej metodom (a), airbrush metodom (b).	23
Slika 18. Iwata High Performance SB Plus airbrush [20].	24
Slika 19. Optički mjerni sustav Aramis [22].	25
Slika 20. Eksperimentalni postav.	25
Slika 21. Preklap na fasetama veličine 200 piksela.	26
Slika 22. Mreža konačnih elemenata veličine 32 piksela na sprej teksturi.	27
Slika 23. Uvećana mreža elemenata veličine 32 piksela na sprej teksturi.	27
Slika 24. Izmjereni (a) pomaci u smjeru osi x i (b) deformacije u smjeru osi x.	28
Slika 25. Lokalni pristup na sprej uzorku: pomak u smjeru x za (a) fasete veličina 10 piksela i (b) 200 piksela.	29
Slika 26. Lokalni pristup na airbrush uzorku: pomak u smjeru x za (a) fasete veličina 10 piksela i (b) 200 piksela.	30
Slika 27. Globalni pristup na sprej uzorku: pomak u smjeru x za (a) elemente veličina 10 piksela i (b) 200 piksela.	31
Slika 28. Globalni pristup na airbrush uzorku: pomak u smjeru x za (a) elemente veličina 10 piksela i (b) 200 piksela.	32
Slika 29. Lokalni pristup na sprej uzorku: deformacije u smjeru x za (a) fasete veličina 10 piksela i (b) 200 piksela.	33
Slika 30. Lokalni pristup na airbrush uzorku: deformacije u smjeru x za (a) fasete veličina 10 piksela i (b) 200 piksela.	34
Slika 31. Globalni pristup na sprej uzorku: deformacije u smjeru x za (a) elemente veličina 10 piksela i (b) 200 piksela.	35
Slika 32. Globalni pristup na airbrush uzorku: deformacije u smjeru x za (a) elemente veličina 10 piksela i (b) 200 piksela.	36
Slika 33. Standardna rezolucija pomaka na sprej uzorku u (a) x smjeru i (b) y smjeru.	38
Slika 34. Standardna rezolucija deformacija na sprej uzorku u (a) x smjeru i (b) y smjeru. ...	39
Slika 35. Standardna rezolucija pomaka na airbrush uzorku u (a) x smjeru i (b) y smjeru. ....	40
Slika 36. Standardna rezolucija deformacija na airbrush uzorku u (a) x smjeru i (b) y smjeru.	41
Slika 37. Standardne rezolucije pomaka na sprej i airbrush teksturi u (a) x smjeru i (b) y smjeru.	42

Slika 38. Standardna rezolucija deformacija na airbrush i sprej teksturi u (a) x smjeru i (b) y smjeru. ....	43
--	----

**POPIS TABLICA**

Tablica 1. CC i SSD korelacijski koeficijenti [2].....	12
Tablica 2. Uzroci pogrešaka kod metode korelacije digitalne slike [2]. .....	20



**POPIS ENGLESKIH SKRAĆENICA**

<b>Oznaka</b>	<b>Značenje</b>
AFM	Atomic Force Microscope
CC	Cross-Correlation
CCD	Charge-Coupled Device
CLSM	Confocal Laser Scanning Microscope
CMOS	Complementary Metal-Oxide-Semiconductor
CT	Computed Tomography
DIC	Digital Image Correlation
MIG	Mean Intensity Gradient
ROI	Region of Interest
SEM	Scanning Electron Microscope
SSD	Sum of Squared Differences
SSSIG	Sum of Square of Subset Intensity Gradients
STM	Scanning Tunneling Microscope
WTP	Water Transfer Printing

## SAŽETAK

Određivanje ponašanja materijala jedna je od glavnih zadaća eksperimentalne mehanike. Procjena odziva materijala uslijed narinutog mehaničkog opterećenja očituje se u vidu mjerenja pomaka i deformacija na ispitnom uzorku. Klasične kontaktne metode mjerenja odziva materijala omogućuju registriranje promjena između samo dvije odabrane točke na mjernoj površini što nije dovoljno kod složenijih režima opterećivanja. Razvojem optičkih metoda mjerenja cijelog polja pomaka i/ili deformacija omogućena je analiza odziva materijala na cijelom području interesa. Najkorištenija optička mjerna tehnika je metoda korelacije digitalne slike. Ova metoda bazira se na praćenju karakterističnih točaka na površini mjernog uzorka u nizu digitalnih slika. Određivanjem promjene položaja predloženih točaka moguće je izmjeriti pomak i/ili deformaciju između njih. Kako bi se moglo provesti mjerenje pomoću korelacije digitalne slike potrebno je na mjernu površinu nanijeti odgovarajuću točkastu teksturu na kojoj se uočavaju karakteristične točke. Obrada podataka, odnosno digitalnih slika, u metodi korelacije digitalne slike moguće je provesti lokalnim i globalnim pristupom. Točnost metode korelacije digitalne slike uvelike ovisi o kvaliteti dobivene teksture, upotrijebljenoj mjernoj opremi i o odabranom pristupu.

U ovom radu prikazani su različiti načini dobivanja umjetne teksture, detaljno su opisani lokalni i globalni pristup metodi korelacije digitalne slike te su izvršena mjerenja na uzorcima s dvije različite umjetne teksture. Teksture na kojima je provedeno mjerenje dobivene su sprej i *airbrush* metodom. Mjerenja su provedena optičkim sustavom *Aramis*, koji se temelji na lokalnom pristupu, i korelacijskim algoritmom *RT3 Correli*, koji daje rezultate globalnog pristupa. Ispitivanja su izvršena na neopterećenim uzorcima kako bi se odredio utjecaj šumova i nesavršenosti mjernog sustava na pouzdanost mjerenja malih promjena pomaka i deformacija. Na temelju dobivenih rezultata pomaka i deformacija određene su standardne rezolucije pomaka i deformacija, koje pokazuju koliki se mali prirasti mjernih veličina mogu pouzdano mjeriti ovom metodom ovisno o veličini fasete ili konačnog elementa.

**Ključne riječi:** korelacija digitalne slike, lokalni i globalni pristup, umjetna tekstura, *airbrush*, standardna rezolucija pomaka, standardna rezolucija deformacija

## SUMMARY

Determination of material behavior is one of the main tasks of experimental mechanics. Estimation of material response due to the applied loading is manifested through the measuring of the displacements and strains on the test sample. The classical contact measurement methods of the material response enable the registration of the changes between only two selected points on the measuring surface, which is not enough when the sample is subject to complex loading regimes. With the development of the optical measurement methods of the entire displacement and/or deformation field, it is possible to analyze the material response over the whole region of interest. The most commonly used optical measurement technique is Digital Image Correlation. The proposed method is based on the tracking of characteristic point on the measuring surface in a series of digital images. By determining the position change of the proposed points, it is possible to measure the displacement and/or strain between them. In order to conduct the measurements via Digital Image Correlation, it is necessary to apply a suitable texture to the measuring surface. Data processing, i.e. digital image processing, in Digital Image Correlation can be carried out by local and global approach. The accuracy of the Digital Image Correlation significantly depends on the quality of the prepared texture, applied measuring equipment and the selected approach.

In this thesis various ways of obtaining artificial texture are presented, the local and global approaches of the Digital Image Correlation are described in detail and measurements are made on samples with two different artificial textures. The textures used for the measurements were made by spray and airbrush. The measurements were performed using the local approach based *Aramis* optical system and the correlation algorithm *RT3 Correli*, which provides the results of a global approach. The investigations were performed on the unloaded samples in order to determine the impact of the noise and the imperfection of the measuring system on the measurement reliability of the small displacement and strain changes. Based on the obtained displacement and strain fields, standard displacement and strain resolution were determined.

Furthermore, the obtained results reveal the smallest displacement/strain increment that can be reliably measured via proposed technique according to the size of the facet or the finite element.

**Keywords:** digital image correlation, local and global approach, artificial texture, airbrush, standard displacement resolution, standard strain resolution

## 1. UVOD

Tijekom provođenja ispitivanja u eksperimentalnoj mehanici, uslijed narinutog opterećenja, na ispitnom uzorku dolazi do promjena koje se očituju u obliku pomaka i deformacija. U području eksperimentalne mehanike najčešće treba odrediti odziv materijala (tj. ponašanje materijala) tako da se mjere vrijednosti pomaka i/ili deformacija kako bi se provjerila granična stanja ili kako bi se validirali analitički odnosno numerički modeli. Određivanje pomaka i deformacija na ispitnom objektu može se izvoditi različitim metodama i instrumentima. Glavna podjela metoda za mjerenje pomaka je na kontaktne i beskontaktno metode. Kontaktne metode zasnivaju se na kontaktu s površinom mjernog objekta, a određuju relativne pomake dviju odabranih točaka na mjernom uzorku iz kojih se mogu izračunati deformacije. Tenzometarske i ekstenzometarske metode najkorišteniji su oblik kontaktnih metoda. Tenzometarske metode najčešće se temelje na mjerenju promjene otpora vodiča u ovisnosti o pomaku i deformaciji. Na mjernu površinu postavlja se tenzometar (tj. mjerena traka) u obliku žičane rešetke, pri čemu se posebna pozornost mora posvetiti da lijepljenje bude provedeno tako da se pomaci i deformacije konstrukcije potpuno vjerno prenose na žičanu rešetku. Mehanički kontaktni ekstenzometar mjeri male linearne pomake kontaktom ticala sa mjernom površinom. S razvojem laserske tehnike i digitalnih kamera, uz mogućnost brzog prijenosa i obrade podataka, razvijaju se nove vrste beskontaktnih ekstenzometara. Videoekstenzometar kamerom prati pomake markera postavljenih na površinu uzoraka, dok laserski ekstenzometar kamerom određuje pomake između laserski projiciranih markera na površini uzoraka. Beskontaktni ekstenzometri određuju pomake na velikom mjernu području, međutim i dalje samo između dvije odabrane točke na mjernom uzorku [1].

Za razliku od beskontaktnih ekstenzometara i kontaktnih metoda, optičke beskontaktno metode određuju raspodjelu pomaka i deformacija na cijelom analiziranom području. Na taj način mjeri se cijelo polje pomaka i deformacija, što pridonosi boljem razumijevanju karakteristika materijala i ponašanja gotovih komponenti. Optičke beskontaktno metode zadnjih desetljeća imaju naglu ekspanziju u industriji i na tržištu, uslijed velikog razvoja mjernih uređaja i softvera za obradu podataka. Prednosti mjerenja optičkim beskontaktnim metodama su velik broj mjernih mjesta na objektu, mogućnost mjerenja u otežanim i ekstremnim uvjetima (visoke temperature), mogućnost mjerenja u situacijama kada kontakt s klasičnom mjernom opremom ne može biti uspostavljen duž cijelog ispitivanja te mogućnost naknadnog mjerenja vrijednosti, koje nisu početno predviđene, iz spremljenog seta fotografija.

Među optičkim beskontaktnim metodama posebno se ističe metoda korelacije digitalne slike, DIC (eng. *Digital Image Correlation*), zbog svoje jednostavnosti. Metoda se bazira na prepoznavanju istih točaka na nizu fotografija te mjerenju njihovih pomaka. Iz DIC analize dobivaju se podaci o ponašanju na površini mjernog objekta. Ovom metodom moguće je, uz odgovarajuću opremu, pouzdano određivanje pomaka i deformacija čak i na mikro i nano razini. Iako DIC mjerenja daju vrlo točne rezultate, zbog različitih parametara kao što su šum kamere, tekstura mjerne površine, promjena temperature u mjernoj okolini itd., javljaju se fenomeni koji unose pogrešku u izmjerene rezultate.

Cilj ovoga rada je odrediti iznose mjernih nesigurnosti koji se javljaju uslijed različitih parametara u ovisnosti o odgovarajućem pristupu metodi korelacije digitalne slike i teksturi površine uzorka.


U prvom dijelu rada detaljno je opisana metoda korelacije digitalne slike uz opise lokalnog i globalnog pristupa metode korelacije digitalne slike. Prikazani su različiti načini dobivanja umjetne teksture te parametri koji unose pogreške u izmjerene rezultate. Potom je u eksperimentalnom dijelu opisano nanošenje dvije umjetne teksture i određivanje pomaka i deformacija komercijalnim optičkim sustavom *Aramis* i korelacijskim algoritmom *RT3-Correli* zasnovanom na metodi konačnih elemenata. Na kraju ovog rada prikazani su rezultati izmjerenih polja pomaka i deformacija. Također je prikazana ovisnost standardne rezolucije pomaka i deformacija o teksturi i pristupu metodi korelacije digitalne slike.

## 2. METODA KORELACIJE DIGITALNE SLIKE

Korelacija digitalne slike (*DIC*) beskontaktna je optička metoda koja služi za određivanje cijelog polja pomaka i/ili deformacija. Svi rezultati mjerenja predstavljaju relativan odnos stanja ispitnog uzorka u deformiranom trenutku s obzirom na početno (tj. neopterećeno) stanje. Iz tog razloga se na početku zabilježava referentna slika, a ostale sve slike snimaju se u deformiranom stanju te se uspoređuju sa referentnom slikom. Tijekom zadnjih desetljeća metoda korelacije digitalne slike intenzivno se razvijala kako bi se smanjila kompleksnost izračuna, dobila velika preciznost i pouzdanost te kako bi se proširilo područje upotrebe.

### 2.1. Primjena metode korelacije digitalne slike

Osnovno područje upotrebe metode korelacije digitalne slike su 2D (tj. ravninska) mjerenja koja su najlakše izvediva zbog svoje jednostavnosti. Za provedbu 2D mjerenja potrebna je jedna nepomična kamera, izvor svjetla i odgovarajući algoritam koji će omogućiti praćenje promjena na zabilježenim digitalnim slikama. Međutim, 2D mjerenja ograničena su samo na ravninska snimanja, tj. ravnina uzorka i os kamere moraju biti okomiti. Klasični optički mjerni postav za 2D DIC prikazan je na slika 1. Budući da se sve slike uspoređuju s početnom, referentom, slikom vrlo je važno da se položaj kamere ne mijenja od trenutka zabilježavanja referentne slike. Svaki pomak kamere prilikom snimanja unosi pogrešku koju u 2D tehnici nije moguće ukloniti. Također je važno da ne dolazi do promjene udaljenosti mjernog uzorka u odnosu na kameru [2].




Slika 1. Shematski prikaz 2D DIC optičkog postava [2].

Za snimanje digitalnih slika kod 2D mjerenja koriste se CCD (eng. *Charge-Coupled Device*) ili CMOS (eng. *Complementary Metal-Oxide-Semiconductor*) kamere. Pomoću


navedenih kamera dobiju se pouzdani rezultati na makro razini, dok se za mjerenja na mikro ili čak nano razini koriste različite vrste mikroskopa. Elektronski mikroskop, SEM (eng. *Scanning Electron Microscope*) najkorišteniji je uređaj za mjerenja na mikro razini. SEM ima veliku prostornu rezoluciju s kojom dobiva vrlo oštre slike, pogodne za dobivanje vrlo točnih rezultata, ali trajanje snimanja traje prilično dugo u usporedbi s optičkim kamerama. Također dolazi do kompleksne distorzije slike te se ona mora ispravljati odgovarajućim korekcijskim postupcima. Kao i kod optičkih kamera, kod SEM-a se javljaju šum tijekom snimanja koji uzrokuje pogreške u rezultatima [3]. Osim skenirajućeg elektronskog mikroskopa, za mjerenja na mikroskali koristi se i laserski konfokalni mikroskop, CLSM (eng. *Confocal Laser Scanning Microscope*). Mjerenja na nano razini još su uvijek ograničena na mjerenja malih pomaka i deformacija, a izvode se pomoću mikroskopa s tuneliranjem, STM (eng. *Scanning Tunneling Microscope*) i mikroskopa atomskih sila, AFM (eng. *Atomic Force Microscope*). Kod navedenih mikroskopa šum tijekom snimanja još uvijek ima prevelik utjecaj na rezultate [4]. Za mjerenja na mikro i nano razinama potrebna je posebna priprema teksture, što je opisano dalje u poglavlju 2.2. Mjerenja na mikro i nano razinama omogućuju bolje razumijevanje utjecaja pukotina na konstrukcije. S njima se može pratiti inicijacija mikropukotine te njezina daljnja propagacija. U ovome radu prikazana su dva pristupa metode korelacije digitalne slike (tj. lokalni i globalni) za 2D mjerenja te su provedena ravninska ispitivanja s jednom CCD kamerom prema Slika 1.

Ukoliko je mjerni objekt zakrivljenog oblika ili dolazi do trodimenzijske deformacije prilikom opterećivanja, potrebno je provesti stereo mjerenja (tj. 3D površinska mjerenja). Za razliku od 2D mjerenja, za izvođenje stereo mjerenja potrebne su minimalno dvije kamere. Budući da se zabilježavanje slika obavlja sa minimalno dvije kamere, potrebno je izvršiti kalibraciju sustava kako bi se odredili unutrašnji i vanjski parametri kamera. Osim toga, podešavaju se senzori za odgovarajući mjerni volumen, leće i kut kamere, otvor blende kamere te polarizacijska stakla. Kalibracija se provodi pomoću kalibracijskih objekata (ploča ili štapova) koji na sebi imaju referentne točke sa konstantnim i unaprijed poznatim udaljenostima. Jednom kalibrirani sustav za određeni mjerni volumen moguće je premještati na bilo koju lokaciju gdje se želi provesti mjerenje, ali je potrebno paziti da se ne poremeti međusobni položaj postavljenih kamera. Na slika 2. prikazan je mjerni postav za stereo mjerenja s dvije kamere. Za snimanje 3D DIC mjerenja najčešće se koriste dvije CCD ili CMOS kamere. S pomoću dvije kamere softver može izračunati sve tri koordinate točke te pomake i/ili deformacije u sva tri smjera.



**Slika 2. Shematski prikaz stereo mjerenja s dvije kamere [1].**

Posebna vrsta 3D snimanja (tj. skeniranja) je računalna tomografija, CT (eng. *Computed Tomography*). Prednost računalne tomografije u odnosu na snimanja slika kod 2D i stereo sustava je u tome što se ne zabilježavaju samo podaci na površini mjernog objekta, već i unutar njegovog cijelog volumena. Mjerni uređaji ovdje nisu kamere već posebni laboratorijski CT uređaj (Slika 3.), koji se sastoji od izvora X-zraka, odgovarajućih filtera zračenja, rotacijskog stola, detektora zraka i jedinice za prikupljanje, obradu i vizualizaciju podataka. Izvor projicira X-zrake na objekt te se one u interakciji s objektom reflektiraju, apsorbiraju ili prođu kroz njega. Detektor registrira zrake koje dođu do njega i zabilježava projekcije skeniranog uzorka. Uz pomoć računala se vizualizira i stvara rekonstruirana slika zone interesa promatranog objekta. Skeniranjem mjernog objekta dobiju se nizovi 2D projekcija iz kojih se kompleksnim algoritmom dobije rekonstruirani volumen. Na isti način kao i kod metode korelacije digitalne slike, skenira se jedan referentni volumen u neopterećenom stanju te se svi ostali volumeni dovode u korelaciju s referentnom kako bi se odredili pomaci i/ili deformacije u objektu [5].




**Slika 3. Osnovni dijelovi CT-uređaja [6].**



## 2.2. Tekstura

Uz karakteristike mjerne opreme, tekstura mjerne površine ima najveći utjecaj na pouzdanost ispitivanja. Mjerna površina mora imati raznoliku teksturu (tj. uzorak) kako bi senzor mogao na svakoj slici odrediti karakteristične točke. Na temelju toga, područje piksela na referentnoj slici može se dodijeliti određenom području piksela u ciljanoj deformiranoj slici. Površina mora biti glatka i ne smije biti sjajna, budući da refleksija uzrokuje loš kontrast i prekomjernu svjetlinu na senzoru kamere. Neki materijali, poput sivog lijeva, prirodno imaju poželjnu površinsku teksturu, ali obično to nije slučaj s drugim materijalima. Zato je potrebna dodatna priprema mjerne površine ispitnog uzorka. Upravo s odgovarajućom teksturom može se utjecaj šumova i nesavršenosti kamere svesti na neznatne vrijednosti. Na mjernu površinu nanose se bijela i crna boja kako bi se dobio točkasti uzorak s različitom raspodjelom intenziteta nijansi sive boje. Idealna bi tekstura trebala imati dobar kontrast između bijele i crne boje te imati po cijeloj površini jednoliku raspoređene točkice jednake veličine. Prosječna veličina točkica bi trebala biti veća 3 do 5 puta od veličine piksela slike. Manje točkice uzrokuju loš kontrast dok točkice 5 puta veće od piksela uzrokuju lošu prostornu rezoluciju [7]. Za manje mjerne površine poželjno je da točkasti uzorak bude finiji i gušći kako bi se mogla prikupiti dovoljna količina podataka o sivoj skali bez prevelikog utjecaja šuma kamere. Kod većih mjernih površina moguća je upotreba krupnijeg i grubljeg točkastog uzorka. Kvaliteta teksture procjenjuje se preko različitih kriterija, od kojih su najvažniji srednji gradijent intenziteta sive skale, MIG (eng. *Mean Intensity Gradient*) i zbroj kvadrata gradijenata intenziteta sive skale u podskupovima, SSSIG (eng. *Sum of Square of Subset Intensity Gradients*) [2]. Umjetna tekstura dobivena *airbrushom* prikazana je na slika 4.



Slika 4. Umjetna tekstura.

Tehnike stvaranja umjetnih tekstura uglavnom su ovisne o području primjene. Najjednostavnije je dobivanje tekstura za mjerenja na makro razini. Međutim, dok se globalni odziv materijala može odrediti ispitivanjem na makro razini, mnogi procesi koji se odvijaju na mikro i nano razini ne mogu se potpuno razumjeti na temelju ispitivanja promatranih na makro razini. To su na primjer inicijacija pukotine i njezina daljnja propagacija. Zbog toga se za potrebe mikroskopskih DIC mjerenja pripremaju posebne teksture za mjerenja na mikro i nano razini.

Najčešća i najjednostavnija metoda za nanošenje teksture na površinu ispitnog uzorka je sprej metoda. Ukoliko je površina sjajna i reflektirajuća, prvo se nanosi nereflektirajuća mat bijela boja. Nakon nanošenja bazne bijele boje, u prolazima se nanosi crna boja u spreju kako bi se napravio točkasti uzorak (tj. stohastički raster). Ovom metodom dobije se potpuno nasumična raspodjela točkica različitih veličina. Ipak zbog jednostavne pripreme i dovoljne točnosti kod osnovnih mjerenja, sprej metoda predstavlja popularnu metodu za pripremu teksture.

Za pripremu finije teksture na makro razini koristi se *airbrush*. Uz odgovarajući *airbrush* i uz pažljivo rukovanje, moguće je dobiti i zadovoljavajuću teksturu za mjerenja na mikro razini budući da se može kontrolirati veličina točkica te njihova gustoća. Navedena kvaliteta teksture se postiže podešavanjem radnog tlaka zraka, podešavanjem promjera sapnice *airbrusha* (tj. protoka boje), odabirom željene razrijeđenosti boje te prilagodbom udaljenosti s koje se boja nanosi. Međutim i s ovom metodom se dobije tekstura nepoznatih karakteristika, kao što su veličina točkica i kontrast.

Budući da sprej i *airbrush* metodom nanošenje teksture ne može točno kontrolirati veličinu točkica i njihovu raspodjelu, pokazala se potreba za izradu tekstura s unaprijed poznatim karakteristikama. Najjednostavnija metoda nanošenja unaprijed poznate teksture izvodi se pomoću valjaka na kojima je izrađena reljefna površina sa željenom veličinom točkica (Slika 5).



Slika 5. Valjci za nanošenje teksture [8].


Na valjke se nanese crna boja te se ona kotrljanjem valjaka po bijeloj podlozi nanosi na površinu. Na predloženi način se relativno brzo dobije tekstura sa jednoliko raspoređenim točkicama jednake veličine. Veličina točkica se prilagođava veličini mjernog područja i željenoj veličini podskupova piksela (tj. faseta). Međutim, valjci za nanošenje rastera praktični su samo za ravne površine, jer kod zakrivljenih površina nije moguće pravilno nanijeti teksturu na cijelom području [8].

Pouzdanije metode dobivanja teksture s unaprijed poznatim karakteristikama dobivaju se numeričkim metodama pomoću računala. Računalno dobivene teksture imaju najintenzivniji kontrast zato što se sastoje samo od bijelih i crnih točkica jednake veličine uz njihovu jednoliku raspodjelu po površini [9]. Takva numerički dobivena tekstura prikazana je na slika 6.




**Slika 6. Numerički dobivena tekstura [9].**

Numerički dobivene teksture potrebno je iz računala prenijeti na mjernu površinu. Nanošenje numeričke teksture provodi se laserskim printanjem teksture na posebni neupijajući papir ili vinil s kojeg se potom prenose na objekt. Papir ne smije upijati toner kako bi se određenim postupcima mogao oslikati na uzorku. Najjednostavniji način prijenosa teksture sa papira na mjernu površinu je glačanjem, kada se pri visokim temperaturama boja sa papira oslikava na površini [10]. Ipak za dobivanje bolje numeričke teksture na mjernoj površini koristi se hidrografika, vodeni prijenos boje na površinu (eng. *Water Transfer Printing*). Papir na kojem je litografski otiskana tekstura sastoji se od tri dijela, prikazanih na slika 7. Na površinu se prvo nanese bijela mat boja, koja ne reagira s vodom, na koju će se otisnuti crni točkasti uzorak. Sa papira se ukloni zaštitni sloj te se sloj sa isprintanom teksturom prsloni na površinu. Prslonjeni se papir potom dobro navlaži s vodom kako bi se tekstura dobro oslikala na površini te kako bi se srednji sloj dezintegrirao. Potom se ukloni sloj s naljepnicom i pričekava da voda na sobnoj temperaturi ishlapi s površine uzorka [11].



**Slika 7. Papir za WTP prijenos teksture [11].**

Za omogućavanje mikroskopskih DIC mjerenja potrebno je dobiti teksture na mikro i nano razinama. U tu svrhu koriste se posebni postupci kako bi se dobio točkasti uzorak na iznimno maloj površini. Jedan od tih postupaka je mikrolitografija u kojoj se zlatnim česticama dobije tekstura pogodna za mjerenja na nanometarskoj razini. Na površinu se pri visokim temperaturama nanese jako tanki sloj polimetilmetakrila (PMMA). Nakon što se sloj učvrsti na podlozi, određena područja se izlože snopu elektronskog zračenja te se dobiju rupe u sloju. Potom se na cijelu površinu katodno nanese tanki sloj zlatnih čestica debljine 20 nanometara. Konačno se sa podloge otapalima ukloni sloj polimetilmetakrila te na površini ostanu samo zlatne čestice veličine nekoliko nanometara [12]. Postupak mikrolitografije prikazan je na slika 8.




**Slika 8. Postupak mikrolitografije: nanošenje sloja PMMA (a), izlaganje snopu elektrona (b), nanošenje sloja zlata (d), konačna tekstura nakon uklanjanja PMMA (e) [12].**

Drugom nano rasterskom metodom se mjerna površina prevlači slojem nano čestica zlata (mogu se koristiti i čestice srebra, bakra i kroma). Potom se uzorak stavlja u reakcijske posude gdje se uzorci zagrijavaju i izlažu atmosferi dušika zasićenog odabranim hlapljivim kemikalijama. Hlapljenjem kemikalija dobije se točkasta tekstura pogodna za mjerenja na nanometarskim mikroskopima [13].

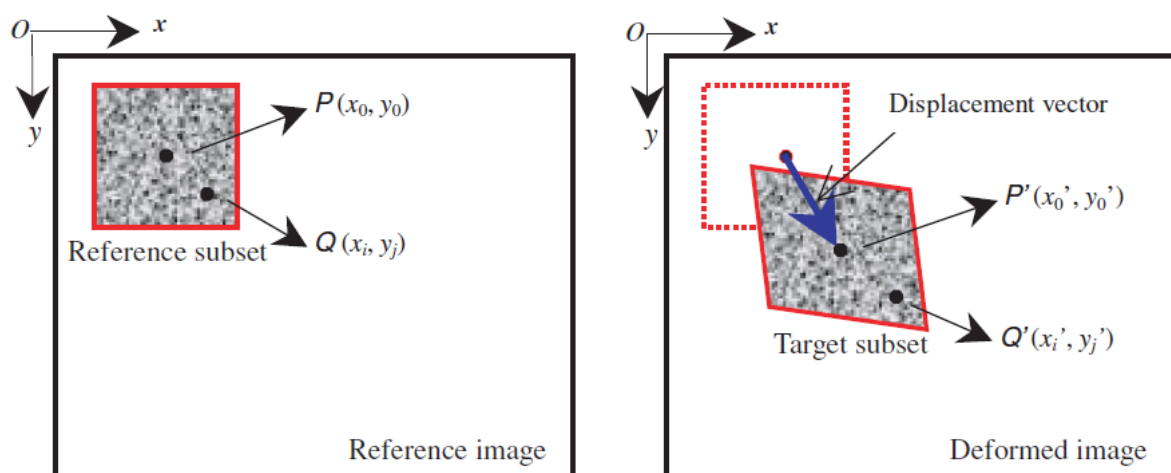
U ovom poglavlju opisane su samo neke metode koje se koriste za nanošenje teksture na ispitni uzorak, ali u praksi postoji još mnogo načina na koje se može nanositi tekstura na mjernu površinu.

### 2.3. Lokalni pristup metodi korelacije digitalne slike

Nakon snimanja prve digitalne slike u neopterećenom stanju, referentne slike, odredi se na njoj područje interesa, ROI (eng. *Region of Interest*) na kojem se provodi metoda korelacije digitalnih slika. Ostale slike zabilježavaju se tijekom i nakon djelovanja opterećenja te se jednostavno nazivaju deformirane slike. Područje interesa se potom diskretizira na manja polja piksela koja se nazivaju fasete (eng. *Facets*). U centru svake fasete nalazi se mjerna točka za koju se računa pomak i deformacija. Fasete su uobičajeno kvadratnog ili pravokutnog oblika, a bitno je da svaka faseta ima karakterističnu raspodjelu intenziteta sive boje koja ih čini međusobno različitima. Metoda počiva na praćenju, tj. poklapanju, dvije ili više karakterističnih faseta na dvije slike, referentnoj i deformiranoj, kao što je prikazano na slika 9.



Slika 9. Pravokutne fasete u referentnoj konfiguraciji (a) i deformiranoj konfiguraciji (b) [1].



Slika 10. Određivanje pomaka i deformiranja fasete [2].

Pretpostavlja se da se oblik fasete mijenja tijekom djelovanja opterećenja te da se u deformiranoj konfiguraciji dobije i deformirani oblik fasete. Međutim, na temelju pretpostavke malih deformacija pretpostavlja se da susjedne mjerne točke, tj. fasete, u referentnoj konfiguraciji ostaju susjedne mjerne točke i u deformiranoj konfiguraciji. Stoga se koordinate točke  $Q'$ , prikazane na slika 10., u deformiranoj slici mogu odrediti iz koordinata točke  $Q$  u referentnoj slici pomoću takozvanih funkcija oblika  $\xi$  i  $\eta$ :

$$\begin{aligned}x'_i &= x_i + \xi(x_i, y_j), \\y'_j &= y_j + \eta(x_i, y_j).\end{aligned}\tag{1}$$

Ukoliko dolazi samo do pomaka krutog tijela između referentne i deformirane slike, tada su funkcije oblike jednake pomaku tijela  $u$  i  $v$ :

$$\xi_0(x_i, y_j) = u, \quad \eta_0(x_i, y_j) = v.\tag{2}$$

Gore navedene funkcije očito nisu dovoljne za opis pomaka uslijed deformacije fasete. Stoga se uvode funkcije oblika prvog stupnja koje mogu opisati translaciju, rotaciju, smicanje, deformaciju u smjeru normale i njihove kombinacije:

$$\begin{aligned}\xi_1(x_i, y_j) &= u + u_x \Delta x + u_y \Delta y, \\ \eta_1(x_i, y_j) &= v + v_x \Delta x + v_y \Delta y.\end{aligned}\tag{3}$$

Osim njih, za opis pomak točke pri kompliciranijim deformacijama koriste se i funkcije oblika drugog stupnja:

$$\begin{aligned}\xi_2(x_i, y_j) &= u + u_x \Delta x + u_y \Delta y + \frac{1}{2} u_{xx} \Delta x^2 + \frac{1}{2} u_{yy} \Delta y^2 + u_{xy} \Delta x \Delta y, \\ \eta_2(x_i, y_j) &= v + v_x \Delta x + v_y \Delta y + \frac{1}{2} v_{xx} \Delta x^2 + \frac{1}{2} v_{yy} \Delta y^2 + v_{xy} \Delta x \Delta y.\end{aligned}\tag{4}$$

U gore navedenim jednadžbama  $\Delta x$  i  $\Delta y$  su udaljenost promatrane točke  $Q$  u odnosu na centar fasete  $P$  po  $x$  i  $y$  osi. Nadalje,  $u_x, u_y, v_x$  i  $v_y$  su gradijenti pomaka referentne fasete, a  $u_{xx}, u_{yy}, u_{xy}, v_{xx}, v_{yy}, v_{xy}$  su gradijenti pomaka drugog reda [2].

Kako bi se odredio stupanj sličnosti između referente i deformirane fasete, potrebno je definirati korelacijski koeficijent, koji je kriterij podudarnosti dviju raspodjela intenziteta sive boje između dvije fasete. Postupak traženja najboljeg podudaranja dovršen je kad se pronađe ekstremna vrijednost korelacijskog koeficijenta, odnosno najveće podudaranje raspodjele intenziteta sive boja po faseti na referentnoj i deformiranoj slici. Na predloženi način pronađen

je položaj centra deformirane fasete (točke  $P$ ) te je time određen i iznos pomaka. Raspodjela intenziteta sive boje pri najvećem poklapanju određena je sljedećom funkcijom:

$$f(x_i, y_j) = g(x'_i, y'_j) + u(x_i, y_j), \quad (5)$$

pri čemu je  $f$  raspodjela intenziteta sive boje po faseti na referentnoj slici,  $g$  raspodjela intenziteta sive boje po faseti na deformiranoj slici, a  $u$  pomak centra fasete između referentne i deformirane slike.

Iako postoje različite vrste korelacijskih koeficijenata, najvažniji korelacijski koeficijenti spadaju u grupe CC kriterija (eng. *Cross-correlation*) i SSD kriterija (eng. *Sum of squared differences*). Njihovi oblici prikazani su u tablica 1.

**Tablica 1. CC i SSD korelacijski koeficijenti [2].**

CC korelacijski kriterij	Definicija
CC [2]	$C_{CC} = \sum_{i,j} [f(x_i, y_j) g(x'_i, y'_j)]$
Normalized CC [2]	$C_{NCC} = \sum_{i,j} \left[ \frac{f(x_i, y_j) g(x'_i, y'_j)}{\bar{f} \cdot \bar{g}} \right]$
Zero-normalized CC [2]	$C_{ZNCC} = \frac{\sum_{i,j} [f(x_i, y_j) - \bar{f}] [g(x'_i, y'_j) - \bar{g}]}{\sqrt{\sum_{i,j} [f(x_i, y_j) - \bar{f}]^2 \sum_{i,j} [g(x'_i, y'_j) - \bar{g}]^2}}$
SSD korelacijski kriterij	Definicija
SSD [2]	$C_{SSD} = \sum_{i,j} [f(x_i, y_j) - g(x'_i, y'_j)]^2$
Normalized SSD [2]	$C_{NSSD} = \sum_{i,j} \left[ \frac{f(x_i, y_j)}{\bar{f}} - \frac{g(x'_i, y'_j)}{\bar{g}} \right]^2$
Zero-normalized SSD [2]	$C_{ZNSSD} = \sum_{i,j} \left[ \frac{f(x_i, y_j) - \bar{f}}{\sqrt{\sum_{i,j} [f(x_i, y_j) - \bar{f}]^2}} - \frac{g(x'_i, y'_j) - \bar{g}}{\sqrt{\sum_{i,j} [g(x'_i, y'_j) - \bar{g}]^2}} \right]^2$


U gornjim izrazima s  $\bar{f}$  i  $\bar{g}$  definirane su srednje vrijednosti intenziteta sive boje po fasetama u referentnoj i deformiranoj slici:



$$\bar{f} = \sqrt{\sum_{i,j} [f(x_i, y_j)]^2},$$

$$\bar{g} = \sqrt{\sum_{i,j} [g(x'_i, y'_j)]^2}.$$
(6)

Sumiranje indeksa  $i$  i  $j$  provodi se po pikselima na području interesa u vertikalnom i horizontalnom smjeru. Važno je napomenuti da su  $C_{CC}$ ,  $C_{SSD}$ ,  $C_{NCC}$  i  $C_{NSSD}$  korelacijski koeficijenti osjetljivi na šumove i način osvjetljenja, dok su  $C_{ZNCC}$  i  $C_{ZNSSD}$  otporniji na utjecaje šumova i načina osvjetljenja, pa se zbog toga samo oni koriste u lokalnom pristupu.  $C_{ZNCC}$  korelacijski koeficijent poprimit će maksimalnu vrijednost na mjestu najvećeg poklapanja faseta, kao što prikazuje slika 11., dok će  $C_{ZNSSD}$  imati minimum na mjestu najvećeg poklapanja faseta. Ako se za funkcije oblika odaberu izrazi (3), korelacijski koeficijenti su funkcija 6 varijabli, dvije komponente pomaka u  $x$  i  $y$  smjeru i četiriju gradijenata pomaka [2].



**Slika 11. Distribucija CC korelacijskog kriterija [2].**

Postupak pronalaženja novog položaja centra fasete kreće sa pretpostavkom novog položaja centra fasete. Pod pretpostavkom malih pomaka i deformacija u deformiranoj se slici, u blizini promatrane fasete, odaberu minimalno tri točke. Za svaki pretpostavljeni položaj točke odredi se iznos korelacijskog koeficijenta. Unaprijeđenom Newton-Raphsonovom metodom određuje se položaj iduće točke prema sljedećem izrazu:

$$p = p_0 - \frac{\nabla C(p_0)}{\nabla \nabla C(p_0)},$$
(7)



pri čemu je  $p_0$  položaj prve pretpostavljene točke,  $\nabla C$  prva derivacija odabranog korelacijskog koeficijenta,  $\nabla \nabla C$  druga derivacija korelacijskog koeficijenta, a  $p$  položaj nove izračunate točke. U novoj točki, odnosno faseti kojoj ona pripada, odrede se korelacijski koeficijenti i njihove derivacije te se određuje položaj iduće točke preko izraza (7). Iteracije traju dok se ne pronađe ekstrem korelacijskog koeficijenta s čim je određen i konačan položaj centra promatrane fasete u deformiranoj slici. Tada se jednostavno odredi koliko je pomak centra fasete u odnosu na referentnu sliku. Nedostatak ovoga pristupa je što rješenje neće konvergirati ukoliko se na putu iteracija naiđe na pukotinu. Tada algoritam registrira da je došlo do diskontinuiteta na površini te se može samo pretpostaviti da je riječ o pukotini [2].

Također je važno napomenuti da se u lokalnom pristupu fasete promatraju neovisno jedna o drugoj te da time nije osiguran kontinuitet pomaka. Zbog toga je mjerenje malih pomaka i deformacija osjetljivo na utjecaj šumova prilikom zabilježavanja slika. Za određivanje utjecaja šumova na mjerenje malih pomaka i deformacija koriste se standardne rezolucije pomaka i deformacija. Standardna rezolucija mjernog sustava je najmanja promjena mjerene veličine koju mjerni sustav (tj. algoritam) može registrirati. Pomoću standardnih rezolucija pomaka i deformacija određuje se koji su mali pomaci ili deformacije stvarno mehaničke prirode, a koji su nastali kao posljedica šumova. Standardna rezolucija pomaka  $\sigma_u$  u lokalnom pristupu određuje se izrazom:

$$\sigma_u = \frac{4\sqrt{2} \cdot \sigma \cdot p_l}{G_f \cdot l}. \quad (8)$$

U gornjem je izrazu  $\sigma^2$  varijacija bijelog Gaussovog šuma,  $p_l$  je fizička veličina jednog piksela,  $G_f$  je srednji kvadratni gradijent slike, a  $l$  je veličina fasete [14]. Standardna rezolucija se ipak jednostavnije i češće određuje eksperimentalnim mjerenjima.

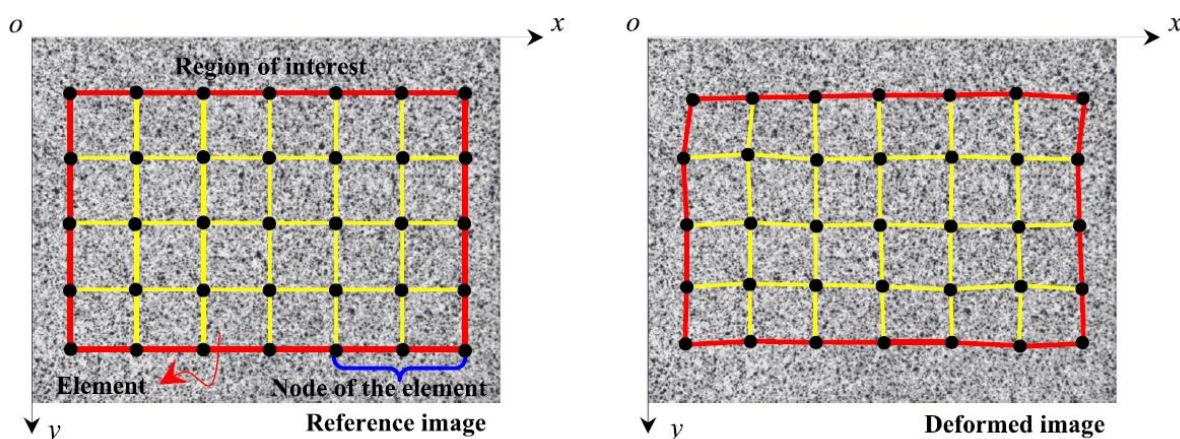
Zbog visoke efikasnosti, lake implementacije i relativno velike preciznosti, lokalni pristup metode korelacije digitalne slike najkorišteniji je u komercijalnim paketima. Budući da se fasete promatraju i računaju neovisno jedna o drugoj, lokalnim pristupom se u realnom vremenu mogu dobiti rezultati pomaka i deformacija na površini. Optički sustav *Aramis*, korišten u ovome radu, također se zasniva na lokalnom pristupu.

U praksi je minimalna veličina faseta u ovom pristupu  $10 \times 10$  piksela. U jednadžbi (8) vidljiva je ovisnost standardne rezolucije pomaka o veličini fasete. Fasete manje od minimalne granice osjetljive su na šumove koji onemogućuju pouzdano mjerenje malih pomaka i deformacija. Međutim, manje fasete u pravilu daju veći broj mjernih podataka i omogućuju praćenje lokalnih promjena. Povećanje faseta ima za posljedicu smanjenje mjerne nesigurnosti,

ali se ne mogu izmjeriti lokalne promjene, tj. pomak i deformacija u zonama manjim od veličine fasete. Veličina faseta mora se također odrediti u ovisnosti o teksturi na mjernoj površini. Za teksture s ostrim kontrastom, vrlo male fasete mogu dati rezultate sa zadovoljavajućom točnošću, dok za teksture sa slabijim kontrastom poželjna je primjena većih faseta. Osim veličine fasete moguće je prilagođavati i korak fasete. Na taj se način ostvaruje preklop između susjednih faseta. Povećanjem koraka smanjuje se gustoća mjernih točaka, što za posljedicu ima kraće vrijeme izračuna pomaka i deformacija. Sa smanjenjem koraka izračun postaje računalno zahtjevniji, ali se povećava broj mjernih točaka [1].

## 2.4. Globalni pristup metodi korelacije digitalne slike

Kod globalnog DIC pristupa također se prvo na referentnoj slici definira područje interesa, ROI. Globalni se pristup temelji također na diskretizaciji slike podskupovima piksela, no mjerne točke više nisu u centru podskupova, nego u vrhovima elemenata (podskupova). Najčešće su korišteni četverokutni elementi, a diskretizacija područja interesa prikazana je na slika 12.



Slika 12. Prikaz područja interesa u referentnoj i deformiranoj konfiguraciji [15].

Raspodjela intenziteta sive boje na referentnoj i deformiranoj slici također se označi sa  $f$  i  $g$ . Očuvanje intenziteta sive boje na obje slike u ovisnosti o poziciji piksela  $\mathbf{x}$  može se, kao i u lokalnom pristupu, izraziti jednažbom:

$$f(\mathbf{x}) = g[\mathbf{x} + \mathbf{u}(\mathbf{x})]. \quad (9)$$

pri čemu je  $\mathbf{u}$  vektor pomaka. Radi lakšeg izvođenja korelacije, koordinate točaka i pomak su prikazani vektorski. Globalni pristup, za razliku od lokalnog, ne počiva na traženju ekstrema korelacijskih koeficijenata, nego na minimiziranju reziduala između referentne i deformirane slike. Razlika između poklapanja raspodjele intenziteta sive boje u referentnoj i

deformiranoj slici naziva se rezidual. U idealnom slučaju, kada je poklapanje potpuno, on iznosi nula:

$$f(\mathbf{x}) - g[\mathbf{x} + \mathbf{u}(\mathbf{x})] = 0. \quad (10)$$

Budući da se u realnosti nikada ne može dobiti potpuno poklapanje između referentne i deformirane slike, potrebno minimizirati rezidual kako bi pogreška rezultata bila što manja. Minimalizacija sume kvadrata razlike reziduala provodi se na cijelom području interesa i zapisuje se na sljedeći način:

$$T = \int_{ROI} \left( f(\mathbf{x}) - g[\mathbf{x} + \mathbf{u}(\mathbf{x})] \right)^2 d\mathbf{x}. \quad (11)$$

Polje pomaka u jednadžbi (11) interpolira se pomoću pretpostavke slabe forme koja se sastoji od vektorske funkcija oblika  $\Psi_n$  i čvorovima pripadajućih stupnjeva slobode gibanja  $u_n$

$$\mathbf{u}(\mathbf{x}) = \sum_n u_n \cdot \Psi_n(\mathbf{x}). \quad (12)$$

Izbor funkcija oblika je potpuno proizvoljan, ali ipak posebno su zanimljive funkcije oblika konačnih elemenata jer otvara mogućnost povezivanja/usporedbe eksperimentalno izmjerenih i numeričke proračunatih pomaka i/ili deformacija. Interpolacijom polja pomaka, problem minimiziranja reziduala, prema jednadžbi 11, sveo se na minimiziranje u odnosu na stupnjeve slobode gibanja čvorova  $u_n$ . Čvorovi kojima su pridruženi stupnjevi slobode gibanja su vrhovi elemenata. Newtonovom metodom, kojom se izbjegava nelinearnost problema, pretpostavkom o malim prirastima pomaka i određenim korekcijama dobiva se sustav čijim se iterativnim rješavanjem dobije traženo polje pomaka:

$$\frac{\partial T}{\partial \mathbf{u}} = [\mathbf{M}] \{d\mathbf{u}\} - \{\mathbf{b}\} = 0. \quad (13)$$

Matrica  $[\mathbf{M}]$  predstavlja DIC matricu i prema [14] zadana je sljedećim izrazom:

$$M_{ij} = \int_{ROI} [\nabla f(\mathbf{x}) \cdot \Psi_i(\mathbf{x})] [\nabla f(\mathbf{x}) \cdot \Psi_j(\mathbf{x})] d\mathbf{x}. \quad (14)$$

Matrica  $[\mathbf{M}]$  sadržava gradijente sive skale slike i funkcije oblika koje interpoliraju polje pomaka.

Vektor  $\{\mathbf{b}\}$  definiran se kao:

$$b_i^n = \int_{ROI} [f(\mathbf{x}) - \tilde{g}^n(\mathbf{x})] [\nabla f(\mathbf{x}) \cdot \Psi_i(\mathbf{x})] d\mathbf{x}, \quad (15)$$

pri čemu je  $\tilde{g}^n$  korigirana deformirana slika. Ona se tijekom svake iteracije mijenja u ovisnosti o iznosu pomaka  $\mathbf{u}$ :

$$\tilde{g}^n(\mathbf{x}) = g(\mathbf{x} + \mathbf{u}^n(\mathbf{x})). \quad (16)$$


Kako bi se smanjilo vrijeme računanja, matrica  $[\mathbf{M}]$  je tijekom iterativnog određivanja prirasta pomaka konstantna, te se samo mijenja vektor  $\{\mathbf{b}\}$ . Iterativni postupak će trajati sve dok se ne postigne kovergencija, odnosno dok korekcija pomaka  $\{\mathbf{du}\}$  ne zadovolji dovoljno traženi kriterij [14].

Izraz (13) koji se dobije minimiziranjem reziduala, analogan je jednadžbi konačnog elementa:

$$\mathbf{K} \cdot \mathbf{v} = \mathbf{b}. \quad (17)$$

Različit je jedino sadržaj matrice krutosti  $\mathbf{K}$  i vektora sila  $\mathbf{b}$ . Matrica krutosti konačnog elementa zamijenjena je matricom koja sadrži gradijente slike i funkcije oblika koje opisuju polje pomaka. Vektor sila definiran u metodi konačnih elemenata sada je vektor razlika između slika koji se iterativno mijenja s obzirom na korekciju deformirane slike. DIC matrica  $\mathbf{M}$  je simetrična, pojasna i pozitivno definirana matrica kao i matrica krutosti osnovnog pravokutnog konačnog elementa. Vektor  $\mathbf{du}$  sadrži prirast pripadajućih stupnjeva slobode gibanja polja pomaka kao i u metodi konačnih elemenata. Također, za opis polja pomaka u globalnom pristupu, odabrane su funkcije oblika osnovnog pravokutnog elementa, Q4 elementa [16].

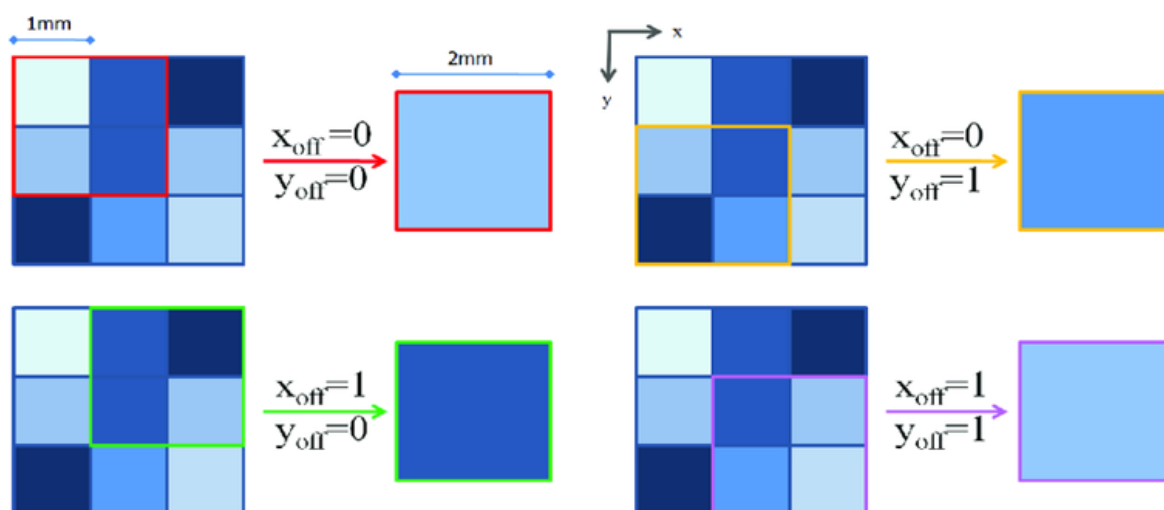
Ukoliko ne dođe do konvergencije rješenja to će se moći odrediti iz polja reziduala. Ako se na mjernoj površini pojavi pukotina koja je manja od veličine elementa, globalni pristup je neće registrirati te na tom mjestu algoritam neće konvergirati. Međutim, kad se na tom mjestu promotri polje reziduala, odnosno razlika između referentne i korigirane deformirane slike, može se uočiti profil pukotine (Slika 13). Stoga se reziduali u globalnom pristupu koriste kako bi se odredilo mjesto nastanka diskontinuiteta u polju pomaka koje se može definirati kao oštećenje materijala.



Slika 13. Polje reziduala korišteno za praćenje rasta mikropukotina.

Još jedna bitna razlika globalnog u odnosu na lokalni pristup je u činjenici da je zadovoljen kontinuitet polja pomaka. Podskupovi (elementi) su povezani čvorovima u vrhovima, a funkcije oblika zadovoljavaju kontinuitet pomaka po stranicama elemenata. Time je osigurano da šumovi koji se javljaju prilikom uzimanja slike imaju puno manji utjecaj na mjerenje malih pomaka nego kod lokalnog pristupa.

Kako bi se smanjio utjecaj šumova kod mjerenja malih pomaka do kojih dolazi zbog prevelikog broja piksela, može se provesti grupiranje piksela. Na taj način dobije se jedan super-piksel (Slika 14.), čija je vrijednost sive skale izračunata interpolacijom vrijednosti sivih skala piksela od kojih je sastavljen. U ovom slučaju iteracija se provodi gore opisanim postupkom od grublje raspodjele super-piksela prema finijoj raspodjeli piksela dok polje pomaka ne konvergira [16].



**Slika 14. Prikaz grupiranja piksela veličine 1x1 mm kojim se dobije super-piksel veličine 2x2 mm [17].**

Standardna rezolucija pomaka globalnog pristupa nije više jednaka za sve mjerne točke kao u lokalnom pristupu. Svaki unutrašnji čvor, mjerna točka, pripada 4 elementa, tako da se funkcije oblika za predloženi čvor protežu na 4 elementa. Stoga je varijanca podijeljena sa 4, dok je standardna rezolucija pomaka podijeljena sa 2, kada se uspoređuje sa vrijednošću jednog Q4 elementa. Uz to potrebno je zadovoljiti i kontinuitet pomaka te se zato standardna rezolucija pomaka množi sa  $\sqrt{3}/2$  i dobije se konačan izraz za standardnu rezoluciju pomaka unutrašnjih čvorova koji glasi:

$$\sigma_u = \frac{\sqrt{6} \cdot \sigma \cdot p_l}{G_f \cdot l}. \quad (18)$$

Svaki čvor na rubu područja interesa pripada u 2 elementa pa se funkcije oblika za rubne čvorove protežu na 2 elementa. Varijanca je u ovome slučaju podijeljena sa 2, dok je standardna rezolucija pomaka podijeljena sa  $\sqrt{2}$ , uspoređeno sa vrijednošću jednog Q4 elementa. Za rubne je čvorove također potrebno zadovoljiti kontinuitet pomaka pa se standardna rezolucija pomaka množi sa  $\sqrt{3}/2$  i dobije se konačan izraz za standardnu rezoluciju pomaka čvorova na rubu područja interesa koji glasi:

$$\sigma_u = \frac{2\sqrt{3} \cdot \sigma \cdot p_l}{G_f \cdot l} . \quad (19)$$

Čvorovi u vrhovima područja interesa pripadaju samo jednom elementu te stoga nije potrebno dijeliti varijancu, a standardna rezolucija pomaka jednaka je standardnoj rezoluciji pomaka jednog Q4 elementa. Međutim, i ovdje je potrebno zadovoljiti kontinuitet polja pomaka, standardna rezolucija pomaka množi se sa  $\sqrt{3}/2$  pa se dobije izraz za standardnu rezoluciju pomaka u vrhovima područja interesa koji glasi:

$$\sigma_u = \frac{2\sqrt{6} \cdot \sigma \cdot p_l}{G_f \cdot l} . \quad (20)$$

Ukoliko se u jednadžbi (20) zanemari uvjet kontinuiteta polja pomaka, tj. ako se ona pomnoži sa  $2/\sqrt{3}$ , dobije se izraz za izračunavanje standardne rezolucije pomaka za lokalni pristup (vidi jednadžba 8). Međutim, tada je mreža elemenata u globalnom pristupu dvostruko gušća od mreže faseta u lokalnom pristupu [14].

Budući da je povezanost čvorova u mreži područja interesa različita, raspodjela standardne rezolucije pomaka više nije uniformna po cijelom području interesa. Zato se uzima srednja standardna rezolucija pomaka koja je zadana izrazom:

$$\sigma_{\bar{u}} = \frac{0.63\sqrt{2} \cdot \sigma \cdot p_l}{G_f \cdot l} . \quad (21)$$

U gornjim je izrazima  $\sigma^2$  varijacija bijelog Gaussovog šuma,  $p_l$  je fizička veličina jednog piksela,  $G_f$  je srednji kvadratni gradijent slike, a  $l$  je veličina elementa [14].

Standardna rezolucija deformacija računa se iz standardne rezolucije pomaka preko sljedećeg izraza:

$$\sigma_\varepsilon = B \cdot \frac{\sigma_u}{l} , \quad (22)$$

gdje je  $B$  bezdimenzijska veličina koja ovisi o načinu računanja deformacija. Osim toga, može se uočiti kako je standardna rezolucija deformacija nekoliko redova veličine manja od standardne rezolucije pomaka, ovisno o veličini elementa  $l$ . Kod globalnom pristupa također vrijedi da se standardna rezolucija pomaka i deformacija najtočnije određuje eksperimentalno.

Globalnim pristupom metode korelacije digitalne slike vrijeme računanja se povećava, no rezultati su pouzdaniji u usporedbi s lokalnim pristupom. Zbog zadovoljenja kontinuiteta polja pomaka u području interesa, a s time i manjim utjecajem šumova prilikom zabilježavanja slike, moguće je minimalnu veličinu elemenata ovim pristupom smanjiti do  $4 \times 4$  piksela. Ispod te granice dolazi ipak do prevelikog utjecaja šumova. Smanjenje veličine elemenata na male iznose piksela omogućuje registriranje pukotina prilikom opterećenja te praćenje njihovog utjecaja na izmjeranim poljima pomaka i/ili deformacija. Međutim, ako su elementi veći od nastale pukotine, moguće je pukotinu registrirati preko polja reziduala.

## 2.5. Uzroci pogrešaka u metodi korelacije digitalne slike


Kao to je ranije navedeno, točnost metode korelacije digitalne slike uvelike ovisi o kvaliteti mjernog sustava i korelacijskom algoritmu. Poznavanje uzroka pogrešaka uvelike pridonosi poboljšanju metode korelacije digitalne slike. Uzroci pogrešaka podijeljeni su u dvije grupe (Tablica 2).

**Tablica 2. Uzroci pogrešaka kod metode korelacije digitalne slike [2].**

Pogreške vezane za mjerni sustav	Tekstura
	Trodimenzijska deformacija i odstupanje od pravog kuta između uzorka i optičke osi aparata
	Distorzija slike
	Šumovi prilikom uzimanja slike i digitalizacije
Pogreške vezane za korelacijski algoritam	Veličina faseta
	Funkcije oblika
	Korelacijska funkcija


Kao što je objašnjeno u poglavlju 2.2., velik utjecaj na točnost rezultata ima tekstura na površini mjernog uzorka. Stoga je potrebno osigurati da tekstura ima dobar kontrast između bijele i crne boje uz jednoliku raspodjelu točkica na površini.

Za uspješno izvođenje 2D mjerenja, ključno je postići okomitost između ravnine uzorka i optičke osi kamere. Ukoliko postoji odstupanje manje od 5 stupnjeva, u mjerenje se unosi greška manja od 0,01 piksela te su rezultati još uvijek zadovoljavajući. Ukoliko nije moguće osigurati okomitost i ako je odstupanje veće od 5 stupnjeva, potrebno je provesti kalibraciju sustava. Kalibracijom je moguće dobiti zadovoljavajuće rezultate s odstupanjima do 30 stupnjeva. Odstupanje od pravog kuta između ravnine uzorka i optičke osi uređaja prikazana je na slika 15. Na slici se vidi kako vertikalni pomak točke na uzorku uzrokuje promjenu udaljenosti promatrane točke od leće fotoaparata, tj. točka se pomakla izvan ispitne ravnine fotoaparata.



**Slika 15. Odstupanje od pravog kuta između uzorka i optičke osi uređaja [18].**

Na brojnim uređajima za snimanje digitalnih slika, uslijed lošijih leća, dolazi do distorzije slike. Kod mjerenja SEM, AFM i STM mikroskopima, zbog velikog povećanja, pojavljuju se složenije distorzije slike nego na klasičnim CCD i CMOS kamerama. Budući da ovo nije problem samo mjerenja metodom korelacije digitalne slike, nego i šire ljudske upotrebe, razvijene su različite metode za uklanjanje utjecaja distorzije na digitalne slike. Na slika 16. prikazan je utjecaj distorzije na izmjerene pomake i deformacije.



**Slika 16. Utjecaj distorzije slike na vrijednosti pomaka [19].**



Na slici 16. a) crvenom i plavom strelicom prikazani su stvarni pomaci na mjernom uzorku, a na slici 16. b) njihovi iznosi na distorziranoj slici. Pomak točke na rubu elementa je manji od stvarnog, dok je pomak točke u sredini kadra veći od realnog.

Prilikom registriranja slike uvijek se pojavljuju neizbježni šumovi, poput Gaussova šuma i termičkog šuma. Utjecaj šumova može se umanjiti korištenjem visoko kvalitetne opreme. Međutim, ako predložena oprema nije dostupna, utjecaja šumova moguće je smanjiti primjenom metode uprosječavanja vrijednosti piksela (eng. *Frame Averaging*) tijekom zabilježavanja slike [2].

Utjecaj veličina faseta opisan je u poglavlju 2.3. Faseta mora biti dovoljno velika kako bi se na njoj mogla odrediti karakteristična raspodjela intenziteta sive boje te da se razlikuje od ostalih faseta. Veličina faseta mora se odrediti u ovisnosti o kvaliteti točkaste teksture. Ukoliko tekstura ima jasan i oštar kontrast, poželjno je da se koriste manje fasete, a ukoliko kvaliteta teksture nije dovoljno dobra, koriste se veće fasete kako bi se smanjio utjecaj šumova.


Odabirom krivih funkcija oblika dolazi do pogrešnog opisa deformacije fasete. Kao što je ranije istaknuto, deformacije male fasete mogu se pouzdano odrediti funkcijama oblika prvog i drugog reda. Funkcije drugog reda daju manju grešku kod opisa kompliciranijih oblika deformiranja no vremenski period analize je duži. Kod globalnog pristupa poželjno je koristiti funkcije oblika konačnih elemenata zbog validacije rezultata dobivenih numeričkim simulacijama. Za provedbu lokalnog DIC pristupa preporuča se korištenje unaprijedene Newton-Raphsonove metode uz upotrebu  $C_{ZNCC}$  i  $C_{ZNSSD}$  korelacijskih koeficijenata, budući da na njih ne utječe promjena osvjetljenja tijekom mjerenja. Osim toga, kod predloženih algoritama najmanji utjecaj šumova prilikom registriranja slika.

### 3. EKSPERIMENTALNA MJERENJA


U sklopu ovoga rada provedena su eksperimentalna mjerenja DIC metodom sa svrhom određivanja standardne rezolucije pomaka i deformacija primjenom lokalnog i globalnog pristupa na dvije različite umjetne teksture. Umjetni rasteri dobiveni su nanošenjem boje klasičnom sprejom metodom i *airbrushom*. Mjerenja su izvršena u Laboratoriju za eksperimentalnu mehaniku. Analizirane slike su zabilježene klasičnim 2D optičkim postavom na neopterećenim uzorcima kako bi se izmjerila standardna rezolucija pomaka i deformacija koja je posljedica samo šumova prilikom registriranja slika. U ovome poglavlju prikazana je priprema uzoraka, provedba mjerenja te obrada dobivenih podataka.

#### 3.1. Priprema uzoraka

Umjetne teksture pripremljene su na metalnoj pločici čija je površina prvo očišćena kako bi se dobila glatka sjajna površina. Budući da je sjajna površina reflektirajuća, na nju je prvo nanescena nereflektirajuća mat bijela boja u spreju (Aqua sprej na bazi vode proizvođača Motip-dupli GmbH, Kurt Vogelsang, Njemačka). Tanki sloj bijele boje sušio se 15 minuta na ispitnim uzorcima. Potom je na jednu površinu nanescena crna boja tako da su sprejom, u nekoliko prolaza, raspršene sitne točkice crne boje koje stvaraju stohastički raster. Crna boja se sušila 5 minuta. Na taj je način dobivena prva umjetna tekstura sprej metodom koja je prikazana na slika 17. a)



a)



b)

Slika 17. Umjetna tekstura dobivena: sprej metodom (a), airbrush metodom (b).

Na drugoj je površini, nakon nanošenja nereflektirajuće bijele boje i sušenja, *airbrushom*, u nekoliko prolaza, nanescena crna boja, koja se potom sušila 5 minuta. Za nanošenje crne boje korišten je *Iwata High Performance-SB Plus airbrush* (vidi slika 18). Korišteni *airbrush* omogućuje nanošenje vrlo sitnih crnih točkica zbog promjera sapnice i igle od 0.2 mm [20]. Radni tlak kompresora kojim se *airbrushom* nanosi crna boja iznosi 2 bara. Umjetna tekstura dobivena *airbrush* metodom prikazana je na slika 17. b)



**Slika 18. Iwata High Performance SB Plus *airbrush* [20].**

Na slika 17. vidi se razlika između teksture dobivene sprej metodom i *airbrush* metodom. Crne točkice dobivene sprej metodom puno su grublje i krupnije od točkica dobivenih *airbrush* metodom, koje su izrazito sitne i fino raspršene. Osim toga, važno je napomenuti kako na *airbrush* teksturi nije moguće prostim okom uočiti crne točkice.


### **3.2. Provedba mjerenja**

Nakon pripreme uzoraka uslijedilo je eksperimentalno mjerenje (tj. zabilježavanje slika). Mjerenja su provedena komponentama optičkog sustava *Aramis*. Kao što je ranije spomenuto, *Aramis* se temelji na lokalnom pristupu korelacije digitalne slike. Mjerni sustav *Aramis*, prikazan na slika 19., sastoji se od podesivog stalka, dviju kamera, izvora svjetla i računala za obradu rezultirajućih digitalnih slika. Za 2D mjerenja, koja su provedena u ovome radu, potrebna je samo jedna kamera. Korištena je kamera Dalsa Falcon 4M60 s frekvencijom od 60 do 480 Hz i rezolucijom 2358 x 1728 piksela. Funkcije samog sustava *Aramis* kontroliraju se softverom. Preko softverskog sustava dostupne su funkcije potrebne za podešavanje mjerenja, procjene, prikaza i ispisa rezultata. *Aramis* koristi operativni sustav *Linux* [21].




Slika 19. Optički mjerni sustav *Aramis* [22].

Za dobivanje valjanih rezultata, budući da se radi o 2D mjerenju, bilo je potrebno ispuniti sve uvjete potrebne za ravninsko snimanje. Na posebno izrađenom prihvatnom sustavu postavljene su mjerne površine i kamera kako bi se osiguralo da je ravnina uzorka okomita na os kamere. Ukoliko ravnina uzorka i os kamere nisu okomiti, dolazi do značajnih pogrešaka pri samom registriranju digitalne slike, koje nisu posljedica šumova kamere. Također, podešeno je osvjetljenje koje kameri osigurava dovoljnu vidljivost točkastog uzorka na mjernoj površini. Optički mjerni postav i prihvat ispitnog uzorka prikazani su na slika 20.



Slika 20. Eksperimentalni postav.


Kao što je ranije istaknuto, mjerenja su izvršena na neopterećenim uzorcima s namjerom dobivanja standardne rezolucije pomaka i deformacija koji su posljedica šumova nastalih tijekom snimanja digitalnih slika. Preporuka je da se predložena procedura provodi na početku svih DIC mjerenja kako bi se ispravno izmjerio utjecaj šumova na mjerenje malih pomaka i deformacija. Pri mjerenju brzina snimanja slika podešena je na jednu sliku u sekundi (eng. *Frames per second*, FPS), a uslikane su 4 digitalne slike. Za određivanje standardne rezolucije pomaka i deformacija korištene su dvije digitalne slike, prva kao referentna, a druga kao deformirana slika u odnosu na referentnu. Dobivene su 16-bitne slike s čim je određeno da se vrijednost sive skale proteže od 0 do  $2^{16}$ . Nakon završetka mjerenja digitalne slike pohranjene su u memoriju, a naknadno su diskretizirane fasetama željenih veličina. Za diskretizaciju digitalne slike odabrane su fasete veličine 10, 16, 32, 64, 128 i 200 piksela. Korak između faseta podešen je na pola veličine fasete kako bi se dobio preklop s kojima bi centar fasete bio na mjestu vrha susjedne fasete, kao što je prikazano na slika 21. Na taj je način omogućena usporedba rezultata dobivenih lokalnim pristupom s rezultatima globalnog pristupa.




**Slika 21. Preklop na fasetama veličine 200 piksela.**

Rezultati dobiveni mjerenjima u *Aramisu* prikazani su u milimetrima. Budući da su veličine faseta i korak između njih podešavani u pikselima, potrebno je rezultate također prikazati u pikselima. Stoga je izvršena kalibracija s kojom se definiralo koliko piksela odgovara jednom milimetru. Na digitalnim slikama uzorka dobivenog sprej metodom jedan milimetar odgovara 17.825 piksela, dok na slikama uzorka dobivenog *airbrush* metodom jedan milimetar odgovara iznosu od 51.9 piksela. Izlazni podaci iz *Aramisa* (tj. polja pomaka i deformacija) obrađeni su naknadno u programskom paketu *Matlab* u kojem je određena standardna rezolucija pomaka i deformacije te su dobiveni dijagrami ovisnosti veličine fasete/elementa o utjecaju šuma registriranog na digitalnoj slici.

Rezultati globalnog pristupa metode korelacije digitalnih slika dobiveni su diskretizacijom područja interesa trokutastim elementima prvog reda (vidi slika 22.), i postupkom opisanom u poglavlju 2.4. Trokutastim elementima se dobiju nesigurniji rezultati malih pomaka i deformacija nego s četvrtastim elementima. Međutim, nestrukturirani trokutasti elementi mogu bolje opisati kompleksniju geometriju ispitnog uzorka oko zakrivljenih ruba. Budući da je mreža konačnih elemenata (Slika 22.) mala te se ne može procijeniti raspodjela sive skale boja u jednom elementu, područje u plavom kvadratu je uvećano i prikazano na slika 23.



**Slika 22. Mreža konačnih elemenata veličine 32 piksela na sprej teksturi.**




**Slika 23. Uvećana mreža elemenata veličine 32 piksela na sprej teksturi.**



#### 4. REZULTATI LOKALNOG I GLOBALNOG DIC PRISTUPA

Tijekom mjerenja uzete su dvije slike za neopterećeno stanje uzroka, te su diskretizirane fasetama, odnosno elementima, veličine 10, 16, 32, 64, 128 i 200 piksela. Radi jasnije usporedbe prikazani su samo ekstremni slučajevi, tj. fasete/elementi veličine 10 i 200 piksela, budući da se na njima najbolje vidi utjecaj veličine fasete/elementa na dobivene pomake i deformacije. Kako bi se izmjerilo polje pomaka i deformacija, digitalne slike analizirane su lokalnim algoritmom ugrađenim u komercijalni sustav *Aramis*. Osim toga, iste slike su uzete u obzir kod *RT3 Correlli* algoritma temeljenog na globalnom DIC pristupu.

Budući da su mjerenja izvršena na neopterećenim uzorcima, dobiveni bi pomaci i deformacije, u odnosu na referentnu sliku, trebali biti jednaki nuli. Međutim, zbog šumova kamere tijekom registriranja slike, te drugih nesavršenosti navedenih u poglavlju 2.5., DIC algoritam registrira određene pomake i deformacije, kao što je prikazano na slika 24. U ovom poglavlju biti će prikazana polja pomaka i deformacija s obzirom na dvije različite teksture i dva DIC pristupa.




Slika 24. Izmjereni (a) pomaci u smjeru osi  $x$  i (b) deformacije u smjeru osi  $x$ .

#### 4.1. Izmjerena polja pomaka

Kao što je ranije navedeno, dobiveni bi pomaci u odnosu na referentnu sliku trebali biti jednaki nuli po cijelom području interesa. Ipak, DIC algoritam registrira određene pomake na mjernoj površini iako je ispitivanje provedeno na neopterećenom uzorku. U ovome poglavlju prikazana su polja pomaka samo u smjeru  $x$  osi za lokalni i globalni pristup, jer su rezultati dobiveni za  $y$  smjer analogni dalje prikazanim rezultatima.


Na slika 25. prikazani su pomaci u smjeru  $x$  osi za sprej teksturu dobiveni lokalnim pristupom metodi korelacije digitalne slike. Za fasete veličine 10 piksela vidljive su lokalne fluktuacije pomaka, odnosno skokovi u iznosu pomaka po cijeloj mjernoj površini. Ti lokalizacijski efekti posljedica su većeg utjecaja šumova na mjerenja s manjim fasetama, što se vidi i u većem iznosu izmjerenih pomaka u odnosu na fasete od 200 piksela. Kod faseta veličine 200 piksela uočava se blaži prijelaz između vrijednosti pomaka po mjernoj površini, uz dva reda veličine manje iznose pomaka u odnosu na fasete od 10 piksela. Ipak vidljivo je da područja uz rubove slike ne mogu biti obrađena za fasete od 200 piksela.



**Slika 25. Lokalni pristup na sprej uzorku: pomak u smjeru  $x$  za (a) fasete veličina 10 piksela i (b) 200 piksela.**




Raspodjela pomaka na mjernoj površini za *airbrush* teksturu nalazi se na slika 26. Isto kao i na teksturi dobivenom sprej metodom, vide se lokalne koncentracije pomaka za fasete veličine 10 piksela, dok je na fasetama od 200 piksela očita blaga „interpolirana“ raspodjela pomaka. Iznosi izmjerenih pomaka za veće fasete također su puno manji od pomaka dobivenih manjim fasetama. Utjecaj texture na iznose dobivenih pomaka očit je usporedbom reda veličine izmjerenih pomaka na teksturama dobivenih sprej i *airbrush* metodom. Veći utjecaj kvalitete texture vidljiv je za veće fasete, gdje su izmjereni pomaci na *airbrush* teksturi red veličine manji od pomaka dobivenih na sprej teksturi. Rubna područja za fasete veličine 200 piksela također nisu mogla biti obrađena.



**Slika 26. Lokalni pristup na *airbrush* uzorku: pomak u smjeru  $x$  za (a) fasete veličina 10 piksela i (b) 200 piksela.**

*RT3 Correli* korelacijskim algoritmom dobiveni su rezultati za globalni pristup metodi korelacije digitalne slike. Orijentacija slika rezultata dobivenih globalnim pristupom, zrcalno je zakrenuta u odnosu na rezultate dobivene lokalnim pristupom. Polje pomaka u smjeru  $x$


dobiveno globalnim pristupom na sprej teksturi prikazano je na slika 27. Uočava se da za manje veličine elemenata postoje također lokalne fluktuacije pomaka, koje su posljedica šumova i nesavršenosti mjerenja, kao i u lokalnom pristupu. Isto tako, ovdje je još očitiji blagi prijelaz između vrijednosti pomaka za elemente veličine 200 piksela. Pomaci dobiveni za elemente od 200 piksela red su veličine manji u odnosu na pomake dobivene za elemente od 10 piksela. Velika je prednost globalnog pristupa mogućnost izračunavanja pomaka na području uz rubove, što nije bilo moguće za fasete veličine 200 piksela u lokalnom pristupu.



**Slika 27. Globalni pristup na sprej uzorku: pomak u smjeru  $x$  za (a) elemente veličina 10 piksela i (b) 200 piksela.**

Na slika 28. vidi se raspodjela pomaka u  $x$  smjeru izračunata globalnim pristupom za *airbrush* teksturu. Također su vidljive lokalne koncentracije pomaka za elemente od 10 piksela

i glatka raspodjela pomaka za elemente veličine 200 piksela. Zanimljiva je usporedba rezultata dobivenih na različitim teksturama za globalni pristup. Za elemente od 10 piksela manji iznos registriranih pomaka dobit će se na teksturi dobivenoj sprej metodom, dok će za elemente od 200 piksela manji pomaci biti na *airbrush* teksturi. To će se odraziti na iznose standardne rezolucije pomaka u ovisnosti o teksturi prikazane na slika 37.

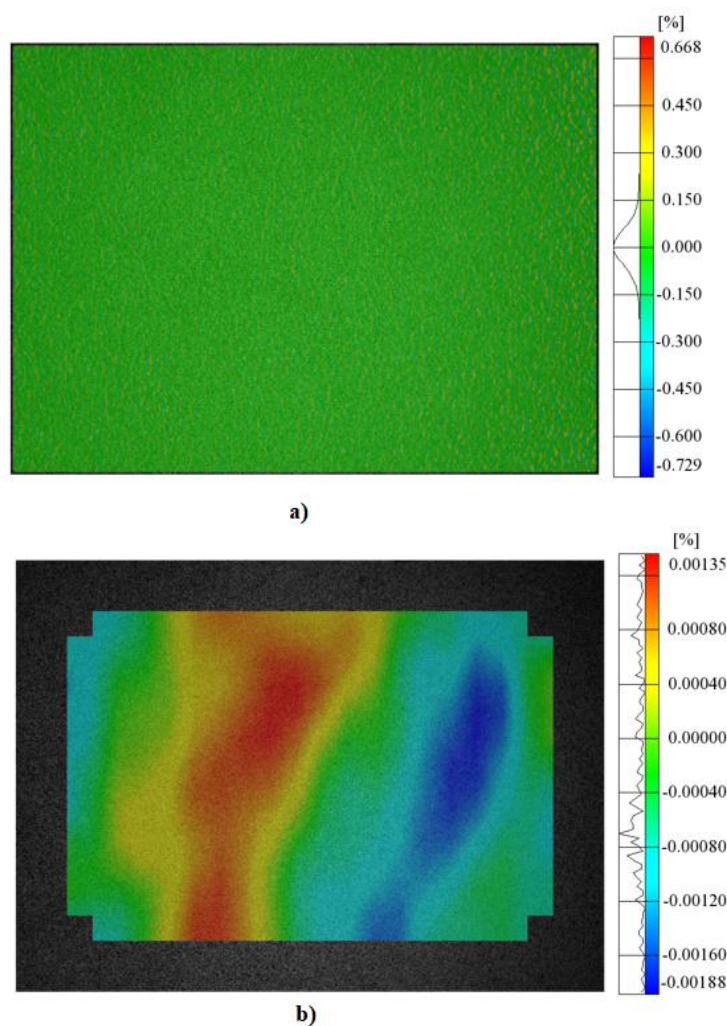


Slika 28. Globalni pristup na *airbrush* uzorku: pomak u smjeru  $x$  za (a) elemente veličina 10 piksela i (b) 200 piksela.

## 4.2. Izmjerena polja deformacija

Polja deformacija dobivaju se na temelju dobivenih polja pomaka. Budući da su mjerenja provedena na neopterećenim uzorcima, iznosi bi deformacija po mjernoj površini trebali biti jednaki nuli. Također su prikazana samo polja deformacija u smjeru  $x$  osi jer su rezultati dobiveni u  $y$  smjeru analogni dalje navedenim rezultatima.

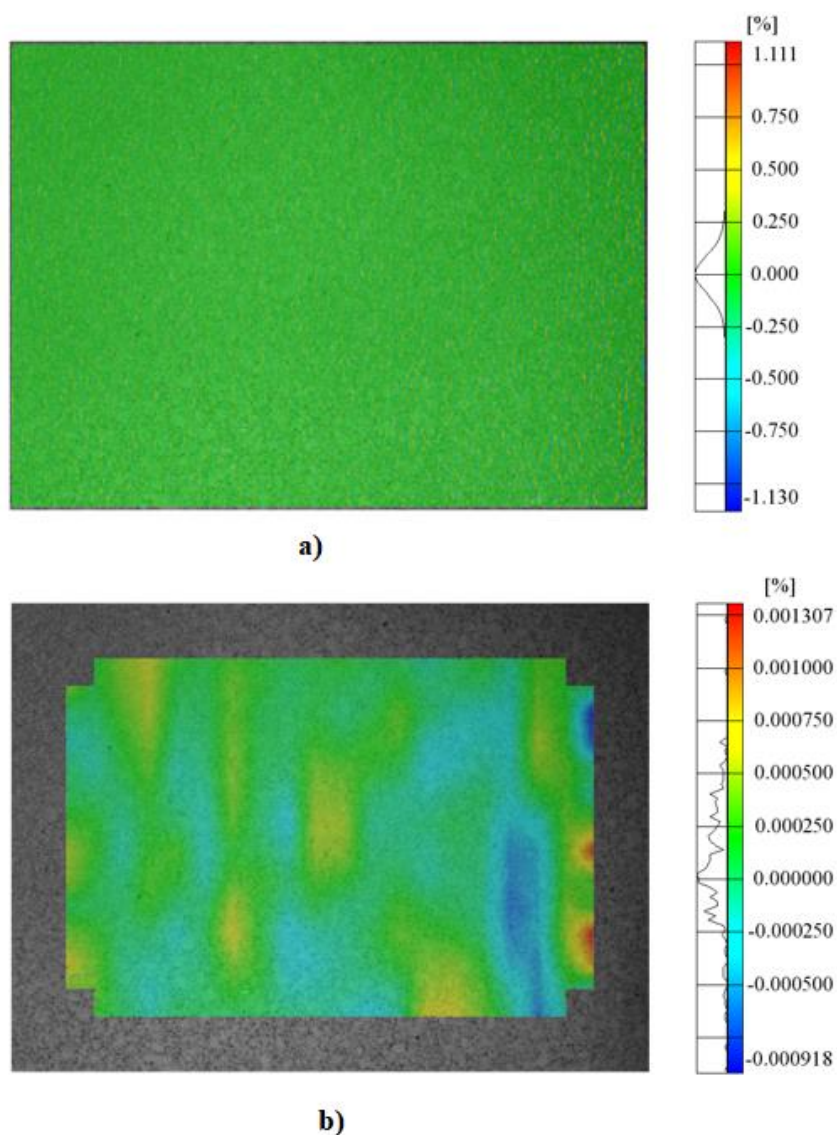
Polje deformacija u  $x$  smjeru, dobiveno, lokalnim pristupom, prikazano je na slika 29. Kao i kod raspodjele pomaka, vidljive su lokalne fluktuacije deformacija na mjernoj površini za fasete veličine 10 piksela i glatka raspodjela deformacija za fasete veličine 200 piksela. To je također posljedica većeg utjecaja šumova prilikom uzimanja slike na mjerenja s manjim fasetama. Iako se većim fasetama dobivaju točniji rezultati, s njima se ne mogu detektirati lokalizacijski fenomeni (tj. mikropukotine, lokalizacija deformacija itd.), ako je ona manja od veličine fasete. Područje uz rub mjerne površine također nije obrađeno za fasete veličine 200 piksela.



**Slika 29. Lokalni pristup na sprej uzorku: deformacije u smjeru  $x$  za (a) fasete veličina 10 piksela i (b) 200 piksela.**




Na slika 30. nalazi se raspodjela deformacija na *airbrush* teksturi dobivena lokalnim pristupom. Uspoređujući teksturu dobivenu sprej metodom i *airbrushom* vidi se da se kod faseta od 10 piksela dobije manji iznos deformacija na sprej teksturi, a kod faseta veličine 200 piksela manji iznosi deformacija dobije se za *airbrush* teksturu. Osim toga, vidljivi su blagi prijelazi između vrijednosti deformacija za fasete od 200 piksela i skokovi u vrijednosti deformacija kod faseta veličine 10 piksela. Iako šumovi prilikom uzimanja slike imaju manji utjecaj na točnost mjerenja kod velikih faseta, njihovim korištenjem ne mogu se opisati plastične deformacije koje su često manje od tolike veličine jedne fasete.



**Slika 30. Lokalni pristup na *airbrush* uzorku: deformacije u smjeru  $x$  za (a) fasete veličina 10 piksela i (b) 200 piksela.**


Prikazi polja deformacija dobivenih globalnim pristupom također su zrcalno zakrenuti u odnosu na prikaz rezultata dobivenih u *Aramisu*. Na slika 31 odmah je uočljivo da je

raspodjela deformacija po elementima konstantna, isto kao i kod osnovnih trokutnih elemenata u metodi konačnih elemenata. Kod velikih se elemenata iznosi deformacija također blago mijenjaju od susjednog do susjednog elementa, dok kod manjih elemenata postoji skokovi u vrijednosti deformacija među susjednim elementima. Vidi se da je globalnim pristupom moguć opis cijelog područja interesa primjenom velikih elemenata, za razliku od lokalnog pristupa.



Slika 31. Globalni pristup na sprej uzorku: deformacije u smjeru  $x$  za (a) elemente veličina 10 piksela i (b) 200 piksela.

Na slika 32. prikazano je polje deformacija na *airbrush* teksturi dobiveno globalnim pristupom. I ovdje je vidljivo da je raspodjela deformacija po elementu konstantna. Iznosi izmjerenih deformacija veći su od onih dobivenih na sprej teksturi, prikazanih na slika 31. To znači da dobivena *airbrush* tekstura nije optimalno prilagođena mjerenju.



Slika 32. Globalni pristup na *airbrush* uzorku: deformacije u smjeru  $x$  za (a) elemente veličina 10 piksela i (b) 200 piksela.

## 5. ODREĐIVANJE STANDARDNE REZOLUCIJE POMAKA I DEFORMACIJA


Kod mjerenja pomaka i deformacija malog iznosa iznimno je važno odrediti koji su pomaci i deformacije stvarno mehaničke prirode, a koji su registrirani zbog nesavršenosti mjernog sustava. Standardna rezolucija govori o najmanjoj promjeni pomaka i deformacija koja se može pouzdano zabilježiti metodom. Upravo se zato standardna rezolucija određuje na neopterećenim uzorcima na kojima nema stvarnih pomaka i deformacija. Budući da metoda korelacije digitalne slike tada registrirane određene pomake, zaključuje se da su oni samo posljedica šumova prilikom uzimanja slike i nesavršenosti mjernog sustava. Na osnovu toga određuje se do koje se granice mogu pouzdano mjeriti promjene pomaka i deformacija.

### 5.1. Usporedba lokalnog i globalnog pristupa

Rezultati standardnih rezolucija pomaka i deformacija, dobivenih s dva pristupa metodi korelacije digitalne slike, bit će prikazani za sprej i *airbrush* teksturu. Kao što je ranije naglašeno, ti su pomaci i deformacije posljedica samo šumova prilikom uzimanja slike i nesavršenosti mjerenja.

Na slika 33. vidi se da su iznosi standardnih rezolucija pomaka u  $x$  i  $y$  smjeru približno jednaki, također i s jednakom tendencijom pada s povećanjem faseta/elementa. Prikazani trendovi pokazuju kako se s povećanjem faseta/elementa smanjuje utjecaj šumova na mjerenja, te da se s tim dobivaju pouzdaniji podaci. Ipak povećanje faseta/elementa ograničava praćenje sitnih/lokalnih promjena pa je potrebno naći kompromis u odabiru veličine fasete/elementa. Slika 33. pokazuje da su najmanje promjene pomaka kod faseta/elementa veličine 10 piksela koji se mogu pouzdano izmjeriti iznose oko  $10^{-2}$  piksela, a sve manje promjene pomaka posljedica su šumova i greške mjernog sustava. Također se vidi da šumovi mjerenja imaju manji utjecaj na globalni pristup, pošto on može izmjeriti manje promjene pomaka (tj. zabilježene su niže vrijednosti standardne rezolucije pomaka).






Slika 33. Standardna rezolucija pomaka na sprej uzorku u (a)  $x$  smjeru i (b)  $y$  smjeru.

Na slika 34. prikazane su standardne rezolucije deformacija za mjerenja na sprej uzorku. Također je vidljiva tendencija pada s povećanjem veličine podskupova piksela. Kod standardne rezolucije deformacija primjetnija je prednost globalnog pristupa u odnosu na lokalni, jer su iznosi standardne rezolucije puno manji za sve veličine elemenata. Red veličine standardne rezolucije deformacija manji je od standardne rezolucije pomaka, kao što je pokazano izrazom


22. Za mjerenje polja deformacija također je potrebno naći kompromis u odabiru veličine fasete/elementa kako bi se mogle pouzdano mjeriti što manje promjene deformacija.



Slika 34. Standardna rezolucija deformacija na sprej uzorku u (a)  $x$  smjeru i (b)  $y$  smjeru.

Standardna rezolucija pomaka na *airbrush* uzorku, prikazana na slika 35., za veće veličine faseta/elementa red je veličine manja u odnosu na sprej teksturu (Slika 33). Vidi se da je za fasete/elemente veličine 200 piksela red veličine manja nego za elemente veličine 10 piksela. Prikazana tendencija pada standardne rezolucije pomaka znači da šumovi mjerenja imaju manji utjecaj na veće fasete/elemente, jer se s njima mogu izmjeriti manje promjene pomaka. Slika 35. pokazuje da se s fasetama/elementima od 200 piksela mogu izmjeriti


promjene pomaka do  $10^{-3}$  piksela. Manje izmjerene promjene pomaka posljedica su šumova. Globalni pristup i ovdje omogućava mjerenje manjih promjena pomaka nego lokalni, pošto na njega šumovi tijekom mjerenja imaju manji utjecaj.




**Slika 35. Standardna rezolucija pomaka na *airbrush* uzorku u (a)  $x$  smjeru i (b)  $y$  smjeru.**

Na *airbrush* teksturi najjasnije je vidljiva prednost globalnog u odnosu na lokalni pristup, jer je iznos standardne rezolucije deformacija, dobivene globalnim pristupom, za sve veličine faseta/elementa red veličine manji, kao što prikazuje slika 36. Tako je za elemente veličine 200 piksela moguće mjerenje promjena deformacija do  $10^{-5}$ , a fasetama od 200 piksela

moguće je mjeriti promjenu deformacije veću od  $10^4$ . Uspoređujući sa slika 34., vidi se da je iznos standardne rezolucije deformacija na *airbrush* teksturi veći nego na sprej teksturi, što pokazuje da dobivena *airbrush* tekstura nije optimalno prilagođena mjerenjima.



a)




b)

Slika 36. Standardna rezolucija deformacija na *airbrush* uzorku u (a)  $x$  smjeru i (b)  $y$  smjeru.

## 5.2. Usporedba sprej i *airbrush* teksture


Pomoću iznosa standardnih rezolucija pomaka i deformacija može se ocijeniti kvaliteta dobivenih tekstura. Dobivene sprej i *airbrush* teksture uspoređene su globalnim pristupom metodi korelacije digitalne slike.

Na slika 37. vidi se standardna rezolucija pomaka na sprej i *airbrush* teksturi. Standardna rezolucija pomaka na *airbrush* teksturi ima izraženiju tendenciju pada što znači da za veće elemente *airbrush* tekstura nadmašuje sprej teksturu, te su na njoj moguća mjerenja promjena pomaka do  $10^{-3}$  piksela. Ipak, slika 37 pokazuje da je za manje elemente na sprej teksturi moguće mjerenje manjih promjena pomaka nego na *airbrush* teksturi. To znači da dobivena *airbrush* tekstura nije prilagođena mjerenjima s manjim elementima.



Slika 37. Standardne rezolucije pomaka na sprej i *airbrush* teksturi u (a) x smjeru i (b) y smjeru.

Na iznosima standardne rezolucije deformacija, prikazanih na slika 38., vidi se neprilagođenost *airbrush* teksture skali izvedenog mjerenja. Sprej tekstura omogućuje bolja mjerenja promjena deformacija nego *airbrush* što ne bi trebao biti slučaj. Za dobivanje bolje *airbrush* teksture trebalo je uzeti *airbrush* sa sapnicom koja bi nanosila veće točke crne boje na površinu. Također je bilo moguće bolje prilagoditi položaj kamere dobivenoj teksturi. Stavljanjem još kojeg distantnog prstena ili približavanjem kamere ispitnom uzorku, dobili bi se pouzdaniji podaci za *airbrush* teksturu.



Slika 38. Standardna rezolucija deformacija na *airbrush* i sprej teksturi u (a)  $x$  smjeru i (b)  $y$  smjeru.

## 6. ZAKLJUČAK

U ovom radu provedena su mjerenja metodom korelacije digitalne slike na dvije različite teksture. Teksture su pripremljene sprej i *airbrush* metodom na očišćenoj metalnoj pločici. Za nanošenje *airbrush* teksture upotrijebljen je *Iwata High Performance-SB Plus airbrush*. Mjerenja su provedena lokalnim i globalnim pristupom metode korelacije digitalne slike. Za dobivanje rezultata lokalnim pristupom korišten je optički mjerni sustav *Aramis*, dok je za dobivanje rezultata globalnim pristupom korišten algoritam *RT3 Correlli*. Optičkim sustavom *Aramis* promatrano područje na mjernoj površini podijeljeno je na kvadratne fasete dok je za mjerenja globalnim pristupom područje interesa diskretizirano trokutastim konačnim elementima prvog reda.

Zabilježene su dvije slike na neopterećenom uzorku kako bi se izmjerila standardna rezolucija pomaka i deformacija koja je posljedica šumova prilikom registriranja slika. Izmjerena polja pomaka i deformacija pokazuju da su izmjerene određene vrijednosti pomaka i deformacija iako su slike zabilježene na neopterećenom uzorku. Dobiveni pomaci i deformacije nisu mehaničke prirode, nego su samo posljedica šumova prilikom uzimanja slike i nesavršenosti mjernog sustava. Cilj ovoga rada bio je odrediti standardne rezolucije pomaka i deformacija u ovisnosti o pristupu metodi korelacije digitalne slike i dobivenim teksturama. Na taj je način evaluirana kvaliteta dobivenih tekstura, te je pokazana usporedba lokalnog i globalnog pristupa.

Dobiveni rezultati mjerenja pokazuju da standardne rezolucije imaju tendenciju pada s povećanjem faseta/elementa. Stoga se zaključuje da šumovi imaju manji utjecaj na mjerenja s većim podskupovima piksela, pa se s njima mogu točnije izmjeriti manje promjene pomaka i deformacija. Ipak, potrebno je pronaći kompromis u odabiru veličine fasete/elementa kako bi se mogla izmjeriti što manja promjena pomaka i deformacija uz mogućnost praćenja sitnih lokalnih efekata, npr. mikropukotina. Pokazano je da globalni pristup nadmašuje lokalni jer za sve veličine elemenata ima manje iznose standardne rezolucije. Može se zaključiti da šumovi imaju manji utjecaj na globalni pristup, te da on omogućava pouzdano mjerenje manjih promjena pomaka i deformacija. Iznosi standardnih rezolucija pomaka pokazuju da je tekstura dobivena *airbrush* metodom dobro prilagođena za mjerenja s većim elementima, dok kod mjerenja s manjim elementima sprej tekstura može pouzdano mjeriti manje promjene pomaka. Standardna rezolucija deformacija pokazuje još veću neprilagođenost dobivene *airbrush* teksture skali mjerenja, jer ju za sve veličine elemenata sprej tekstura nadmašuje. Kako bi se postigle niže vrijednosti standardne rezolucije pomaka i deformacija na *airbrush* teksturi

potrebno je promjeniti razinu promatranja zone interesa približavanjem senzora kamere mjernoj površini ili korištenjem *airbrusha* sa većom sapnicom.



## LITERATURA

1. M. Surjak.; Validacija numeričkih modela mehaničkog ponašanja životinjskih i ljudskih kostiju; Sveučilište u Zagrebu, Fakultet Strojарstva i Brodogradnje; Zagreb, 2015
2. B. Pan, K. Qian, H. Xie, A. Asundi; Two-dimensional digital image correlation for in-plane displacement and strain measurement: a review; School of Mechanical and Aerospace Engineering, Nanyang Technological University, Singapore, 2009
3. A.D. Kammers. S. Daly; Digital Image Correlation under Scanning Electron Microscopy: Methodology and Validation; Society for Experimental Mechanics, United States of America, 2013
4. J. Kang; Microscopic Strain Mapping Based on Digital Image Correlation; School of Welding Engineering Technology, Kirikland Lake, Ontario, Canada, 2008
5. A. Cantatore, P. Muller; Introduction to Computed Tomography; DTU Mechanical Engineering; 2011
6. I. Bartulić; Točnost i preciznost rezultata dimenzionalnih mjerenja kod primjene računalne tomografije; Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje, Zagreb, 2016.
7. G. Lionello, L. Cristofolini; A Practical Approach to Optimizing the Preparation of Speckle Patterns for Digital Image Correlation; University of Bologna, Bologna, Italy, 2014
8. <https://www.correlatedsolutions.com/speckle-kit/>
9. G. Stoilov, V Kavardzhikov, D. Pashkouleva; A Comparative Study of Random Pattern for Digital Image Correlation; Bulgarian Academy of Science, Sofia, Bulgaria, 2012
10. S. Gualtieri; Novel Technique for DIC Speckle Pattern Optimization and Generation; Politecnico di Milano, Milano, 2012
11. Z. Chen, F. Zhu, C. Quan, X He; A Method to Transfer Speckle Patterns for Digital Image Correlation; Southeast University, Nanjing, China, 2015
12. A. Guery, F. Latourte, F. Hild, S. Roux; Characterization of SEM Speckle Pattern Marking and Imaging Distortion by Digital Image Correlation; Laboratoire de Mécanique et Technologie (LMT-Cachan), Cachan Cedex, France, 2013
13. M. A. Sutton, W. A. Scrivens, Y. Luo, S.A. Collette, X. Li; Development of Patterns for Digital Image Correlation Measurements at Reduced Length Scales; University of South Carolina; Columbia, United States of America, 2006
14. F. Hild, S. Roux; Comparison of Local and Global Approaches to Digital Image Correlation; Laboratoire de Mécanique et Technologie (LMT-Cachan), Cachan Cedex, France, 2012
15. B. Wang, B. Pan: Subset-based local vs. finite element-based global digital image correlation: A comparison study; Institute of Solid Mechanics, Beihang University, Beijing 100191, China, 2016
16. G. Besnard, F. Hild, S. Roux; „Finite-Element“ Displacement Field Analysis from Digital Images; Laboratoire de Mécanique et Technologie (LMT-Cachan), Cachan Cedex, France, 2006
17. R. Guidotti, R. Sinibaldi, C. De Luca, A. Conti, R. J. Ilmoniemi; Optimized 3D co-registration of ultra-low-field and high-field magnetic resonance images; University G. D'Annunzio of Chieti and Pescara, Chieti, Italy, 2018.
18. <https://www.gom.com/services/gom-training/webinars.html>

19. M. Frančić Smrkić, J Koščak, D. Damjanović; Primjena 2D digitalne analize slike za mjerenje pomaka i širine pukotina na AB elementima; Sveučilište u Zagrebu, Građevinski fakultet, Zagreb, 2018
20. Iwata-Airbrush, Operating Instruction Manual, ANEST-Iwata, Sjedinjene Američke Države, 2014.
21. Aramis User Manual – Software, GOM mbH, Njemačka 2009.
22. Aramis User Information - Hardware. GOM mbH, Njemačka 2009.